

**Sveučilište u Zagrebu
Ekonomski fakultet
Diplomski studij Menadžment**

**ULOGA UMJETNE INTELIGENCIJE U ORGANIZACIJSKOJ
STRUKTURI AMBIDEKSTERNE ORGANIZACIJE**

**THE ROLE OF ARTIFICIAL INTELLIGENCE IN THE
ORGANISATIONAL STRUCTURE OF THE AMBIDEXTROUS
ORGANISATION**

Diplomski rad

Tin Nemčić, 0067525346

Mentor: Izv. prof. dr. sc. Goran Vlašić

Zagreb, rujan, 2019.



Sveučilište u Zagrebu
Ekonomski fakultet



IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija.

Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

U ZAGREBU, 26. 09. 2019.
(mjesto i datum)


(vlastoručni potpis studenta)

SADRŽAJ

SAŽETAK I KLJUČNE RIJEČI NA HRVATSKOM JEZIKU

SAŽETAK I KLJUČNE RIJEČI NA ENGLESKOM JEZIKU

1. UVOD	1
1.1. Područje i cilj rada	1
1.2. Izvori i metode prikupljanja podataka	1
1.3. Sadržaj i struktura rada	2
2. AMBIDEKSTERNA ORGANIZACIJSKA STRUKTURA	3
2.1. Pojemno određenje i vrste organizacijskih struktura	3
2.2. Pojemno određenje ambideksterne organizacije i organizacijske strukture.....	8
2.3. Uloga ambideksternih organizacija u uspješnosti poduzeća	13
3. UMJETNA INTELIGENCIJA I NJEN UTJECAJ NA POSLOVANJE	17
3.1. Pojemno određenje umjetne inteligencije	17
3.2. Utjecaj umjetne inteligencije na poslovanje poduzeća.....	21
3.3. Utjecaj umjetne inteligencije na promjene organizacijskih struktura	26
4. EMPIRIJSKO ISTRAŽIVANJE O ULOZI UMJETNE INTELIGENCIJE U ORGANIZACIJSKOJ STRUKTURI AMBIDEKSTERNE ORGANIZACIJE.....	33
4.1. Metodologija istraživanja	33
4.2. Rezultati istraživanja	34
4.3. Ograničenja istraživanja	39
5. ZAKLJUČAK	41
POPIS IZVORA	43
POPIS SLIKA	46
POPIS TABLICA.....	46
PRILOZI.....	46
ŽIVOTOPIS KANDIDATA	47

SAŽETAK I KLJUČNE RIJEČI NA HRVATSKOM JEZIKU

S obzirom na recentnu popularnost umjetne inteligencije u znanstvenoj te poslovnoj literaturi i nagađanja o posljedicama uvođenja iste u organizacije, cilj ovog rada bio je kroz dubinske intervjue iz tri aspekta: tehnološkog, strateškog i aspekta ljudskih potencijala, otkriti koja će biti uloga umjetne inteligencije u organizacijskim strukturama ambideksternih organizacija, s obzirom na dokazanu superiornost istih u odnosu na druge organizacijske strukture. Nalazi istraživanja ukazuju na to da će na eksploatacijskoj strani ambideksterne strukture značajan utjecaj imati automatizacija poslovanja koja će primarno utjecati na rezanje troškova kroz ukidanje pojedinih funkcija (npr. administracije, računovodstva, proizvodnje) dok će na eksploracijskoj strani strukture umjetne inteligencija u obliku softvera i temeljena na velikim količinama podataka omogućavati kreiranje disruptivnih inovacija na temelju spoznaja do kojih ljudski um nije u stanju doći ili je manje ekonomski isplativo. Kako bi to bilo moguće predlaže se da centralna funkcija na obje strane strukture postane funkcija IT-a koja će objediniti implementiranje novih tehnologija, prikupljanje i obradu podataka te donošenje zaključaka, odnosno istraživanje i razvoj te koordiniranje nižih razina organizacije u suradnji s Upravom, a osobu koja bi koordinirala eksploatacijskom i eksploracijskom stranom strukture predlaže se pozicija CTO-a. Dok u dugom roku sa sve većom automatizacijom i brisanjem funkcija je moguće i postupno nestajanje formalnih organizacija.

Ključne riječi: umjetna inteligencija, automatizacija, ambideksterna organizacija, eksploatacija, eksploracija, organizacijske strukture

SAŽETAK I KLJUČNE RIJEČI NA ENGLISKOM JEZIKU

Given the recent popularity of artificial intelligence in the scientific and business literature and speculations about the consequences of introducing artificial intelligence into organisations, the aim of this paper was to find out, through in-depth interviews from three aspects: technological, strategic and human resources, what the role of artificial intelligence in organisational structures of ambidextrous organizations is, given their proven superiority over other organisational structures. Research findings indicate that the automation will have

significant impact on exploitation side of the ambidextrous structure, primarily through cost-cutting caused by the elimination of certain functions in the organisations (i.e. administration, accounting, manufacturing), while on the exploration side, artificial intelligence in the form of software and based on big data will enable creation of disruptive innovations based on insights that the human mind is unable to comprehend. To make this possible it is suggested that a central function on both sides of the structure becomes an IT function, which will integrate the implementation of new technologies, data collection and processing, and drawing insights, as well as coordinate lower levels of the organization in collaboration with the Board, while the CTO position is proposed as a responsible party for coordinating the exploitation and exploration side of the structure. In the long run, with the increasing automation and deletion of organisational functions, the gradual disappearance of formal organisations is possible.

Key words: artificial intelligence, automation, ambidextrous organisation, exploitation, exploration, organisational structures

1. UVOD

1.1. Područje i cilj rada

Cilj ovog rada bio je kroz postojeću literaturu na temu ambideksternih organizacijskih struktura te umjetne inteligencija doći do spoznaja o trenutnom stanju razvoja, mogućnostima i ograničenjima te provesti empirijsko istraživanje kako bi se utvrdila uloga umjetne inteligencije u organizacijskoj strukturi ambideksternih organizacija. Tema je izabrana zbog toga što je u stručnoj, ali i široj javnosti u posljednje vrijeme mnogo priča i teorija o tome kako će umjetna inteligencija utjecati na organizacije te koliko će poslova i na koji način biti promijenjeno, odnosno zamijenjeno umjetnom inteligencijom. S obzirom da su se ambideksterne organizacije pokazale kroz znanstvena istraživanja kao superiorne drugim oblicima organizacija, rad je bio usmjeren na potencijalnu ulogu umjetne inteligencije s obzirom da će obje teme vrlo izgledno biti aktualne duži niz godina u poslovnom svijetu.

1.2. Izvori i metode prikupljanja podataka

Za pisanje rada primarno su korišteni znanstveni članci na temu ambideksternih organizacija te umjetne inteligencije koji su pribavljeni preko platforme Google Scholar. Osim navedenog, korištena je i literatura nekoliko kolegijsa na Ekonomskom fakultetu u Zagrebu, ponajviše Marketinga inovacija i Organizacije.

Za provođenje empirijskog istraživanja korištena je metoda polustrukturiranih dubinskih intervjua na prigodnom uzorku eksperata u Republici Hrvatskoj iz znanosti i prakse koji su imali iskustvo s umjetnom inteligencijom te postavljanjem organizacijskih struktura u poduzećima. Do uzorka eksperata došlo se osobnim kontaktom ili elektroničkim putem nakon pretrage potencijalnih sugovornika na Internetu. Intervjui su snimani te transkriptirani.

1.3. Sadržaj i struktura rada

Rad je strukturiran u 5 poglavlja. Nakon Uvoda, u drugom poglavlju je cilj pojmovno odrediti organizacijske strukture te ambideksternu organizacijsku strukturu kao poseban oblik te prikazati utjecaj ambideksternih organizacija na poslovanje poduzeća. U trećem poglavlju primaran fokus je na pojmovnom određenju umjetne inteligencije te njenom utjecaju na poduzeća i organizacijske strukture. U četvrtom poglavlju prikazano je provedeno empirijsko istraživanje s korištenom metodologijom istraživanja, dobivenim rezultatima te postojećim ograničenjima istraživanja. U petom poglavlju donose se zaključci rada te se ukazuje na potencijalna daljnja istraživanja na istu temu.

2. AMBIDEKSTERNA ORGANIZACIJSKA STRUKTURA

2.1. Pojmovno određenje i vrste organizacijskih struktura

Povijesno gledano, Cohen (2013.) ističe dvije ličnosti koje su imale značajan utjecaj na dizajniranje poslova i organizacija u novije vrijeme. To su Adam Smith, koji je u svojem djelu *Bogatstvo naroda* u 18. stoljeću, detaljno opisao najefikasniji način izrade pribadača te Frederick Winslow Taylor koji je u prvoj polovici 20. stoljeća ekstenzivno pisao o efikasnom organiziranju zadataka u poslove te nagradama koje će potaknuti radnike na bolji rad. Same organizacijske strukture su nakon prvih teorijskih modela koje je Taylor razvio, kroz drugu polovicu 20. stoljeća, doživjele pomak od funkcijskih prema višedimenzionalnima, dok se pred kraj 20. stoljeća javljaju i novi teorijski i praktični oblici poput među-funkcijskih timova (Zenger, Hesterly, 1997.).

Same organizacije, iz teorijske perspektive, preko organizacijskih struktura definiraju distribuciju moći, resursa i odgovornosti kroz različite funkcije i jedinice (Lavie, Stettner, Tushman, 2010.), odnosno organizacijski oblici moraju rješavati četiri ključna problema: podjelu zadataka, alokaciju zadataka, raspodjelu nagrada te informacijske tokove (Puranam, Alexy, Reitzig, 2014.).

Mintzberg (1980.) navodi kako se organizacijsko strukturiranje fokusira na podjelu rada misije organizacije u mnogo specifičnih zadataka i potom se tim zadacima koordinira kako bi se misija ispunila na ujedinen način, odnosno prema Mintzbergu se organizacijska struktura postavlja odozgo prema dolje. March (1963.) iznosi suprotne stavove koji se temelje na formiranju organizacijskih odnosa odozdo prema gore, odnosno da kompozicija organizacija nije zadana, nego se pregovara te ciljevi organizacija nisu postavljeni, nego se dogovaraju. U skladu s time, Cohen (2013.) navodi kako poslovi nisu dizajnirani, nego su često riješeni kroz kombinaciju pregovaranja, primjenu ekspertize, razgovore, primjenu moći i upotrebu raznih zanimanja. Isti autor ističe kako preveliki fokus na formalni dizajn poslova, odnosno organizaciju, nije najbolji način za razumijevanje što ljudi rade na svojoj poziciji, što je posebice vidljivo u radu s tehnologijom koja pruža priliku da se poslovi strukturiraju na neočekivane načine.

Ljudi kao vrsta mogu živjeti u različitim okruženjima za razliku od drugih bića radi kulture koja dozvoljava brzu akumulaciju boljih strategija za eksploataciju lokalnog okruženja u odnosu na genetsko nasljeđe pa su tako i organizacije dizajnirane na načine koji omogućuju prednosti u odnosu na individualno djelovanje kroz zajedničke sustave vrijednosti, selekciju, socijalizaciju i sustav nagrađivanja (O'Reilly, Harreld, Tushman, 2009.). U literaturi se najčešće spominje akumulacija znanja kao ključna prednost organizacija. Tako Zenger, Felin i Bigelow (2011.) navode kako se razmjena znanja unutar organizacija događa radi povećane socijalizacije unutar granica organizacije dok Arrow (1974.) tvrdi kako organizacije (ali i ostali društveni kolektivi) mogu steći više informacija nego pojedinac. Jednostavne forme društvenog učenja smanjuju troškove individualnog učenja dopuštajući pojedincima da selektivno koriste signale iz okruženja, odnosno bez društvenog učenja i znanja svaki pojedinac bi bio primoran učiti sve sam (O'Reilly, Harreld, Tushman, 2009.).

Iako su u načelu prevladale prednosti organizacija te su se iste neprekidno razvijale, postoje i nedostaci kod organizacija koje je važno istaknuti. Naime, unutar organizacija dolazi do politike i borbi utjecaja koje se događaju kada se nepotrebno utječe na aktivnosti i nagrade zaposlenika koje potom diskreditiraju i negiraju potencijalne benefite koji se događaju radi delegiranja zadataka (Zenger, Felin, Bigelow, 2011.). Dodatno, postoji mogućnost da poduzetnici-menadžeri ne posjeduju znanja formiranja organizacijskih struktura i delegiranja što umanjuje moguće benefite (Zenger, Felin, Bigelow, 2011.).

S obzirom na navedeno, nameće se da je centralna uloga u poduzeću ona poduzetnika ili menadžera. Točnije, poduzetnik ili menadžer je centralna figura i veza između tržišta i hijerarhije (Zenger, Felin, Bigelow, 2011.). Također, prema Zengeru i suradnicima (2011.) središnja uloga poduzetnika-menadžera je u sastavljanju strateškog skupa komplementarnih sredstava i aktivnosti, bilo postojećih ili predviđenih, koji će kombiniranjem stvoriti vrijednost za organizaciju. To se postiže odlukama koje aktivnosti će se odvijati unutar organizacije, a koje aktivnosti će biti prepuštene tržištu ili ugovaranju s vanjskim partnerima. Samo odlučivanje zahtijeva detaljnu analizu troškova i koristi svake alternative od strane menadžera, kao i identifikacija parametara koji formiraju i imaju utjecaj na troškove i koristi. Navedeno ukazuje da sami poduzetnik-menadžer mora imati potrebno razumijevanje, odnosno znanje da prepozna vrijednost koju drugi ne vide. Osim pronalaska vrijednosti, poduzetnik-menadžer unutar granica organizacije ima i moć motiviranja i davanja naredbi zaposlenicima da izvršavaju specifične zadatke i time omogućava koordinaciju napora unutar organizacije. Kako bi koordinirao rad zaposlenih te stvarao vrijednost, smatra se kako je

neophodan zadatak menadžera osigurati protok znanja unutar organizacije kroz postavljanje jasne organizacijske strukture (Zenger, Felin, Bigelow, 2011.).

S druge strane, pojedinci traže uzroke, ciljeve i svrhu unutar organizacija koja odgovara njihovim aspiracijama i idejama, odnosno organizacije i kolektivi nastaju gdje se pojedinci odlučuju uključiti određenom zajedničkom ili društvenom cilju koji odgovara njihovim *ex ante* aspiracijama, preferencijama, identitetima i interesima (Felin, Lakhani, Tushman, 2017.). Stoga ključno za efikasno iskorištavanje tržišta je otkrivanje postavki organizacija u kojima će sebični interesi pojedinaca (učesnika na tržištu) biti poravnati s interesima poduzetnika ili menadžera, točnije gdje će heterogeni pojedinci djelovati između sebe i s vremenom samostalno izabrati djelovati sa sličnima sebi (Zenger, Felin, Bigelow, 2011.). Osim udruživanja radi istih ciljeva, psihološki faktori poput zavisti i uspoređivanja s drugima, mogu imati važnu ulogu u procesu izbora pojedinaca u kakvom tipu i strukturi organizacije će sudjelovati (Nickerson, Zenger, 2008.). Iako se navedeno čini vrlo logično u današnje vrijeme, ono je produkt nedavnih zbivanja i znanstvenih istraživanja u 21. stoljeću te se protivi široko prihvaćenom modelu u 20. stoljeću Coasea (1937.) u kojem ljudi rade jer im je tako naređeno/zadano. S razvojem društava za očekivati je da će pojedinci sve više pažnje pri izboru organizacija za rad posvećivati usklađenosti identiteta i društvenih ciljeva organizacija sa svojim vlastitima (Felin, Lakhani, Tushman, 2017.).

Pojedinci, odnosno zaposlenici se unutar organizacija, prema Mintzbergu (1980.) mogu svrstati u 5 osnovnih dijelova organizacije. Prvi dio je operativna jezgra koja uključuje sve zaposlenike koji proizvode osnovne proizvode i usluge organizacije ili direktno podupiru njihovu proizvodnju. Drugi je strateški vrh koji se sastoji od glavnih menadžera organizacije i njihovog osoblja. Treći je središnja linija koja se sastoji od menadžera koji se nalaze na direktnoj liniji formalnog autoriteta između članova strateškog vrha i operativne jezgre. Četvrti dio je tehnostuktura koja se sastoji od analitičara izvan formalne linijske strukture, koji primjenjuju analitičke tehnike kako bi se normalan dnevni posao mogao odvijati (npr. računovođe). Peti dio je pomoćno osoblje koje pruža indirektnu podršku ostatku organizacije (npr. pravni savjetnici).

Osim osnovnih dijelova organizacije, odnosno pozicioniranja pojedinaca u istima, bitan čimbenik u formiranju konačnih organizacijskih struktura poduzeća, prema Mintzbergu (1980.) su parametri dizajna organizacije. Mintzberg kao glavne parametre koji utječu na dizajn organizacija navodi: specijalizacija posla, formalizacija ponašanja, trening i

indoktrinacija, grupiranje jedinica, veličina jedinica, decentralizacija, starost i veličina organizacija, tehnički sistemi te faktori moći. Specijalizacija posla je glavni parametar za podjelu rada unutar organizacije, odnosno koliko će zadataka i njihova širina biti unutar jedne pozicije te kolika će biti kontrola zaposlenika nad tim zadacima. Formalizacija ponašanja opisuje razinu standardiziranosti poslovnih procesa, kroz pravila, procedure, priručnike, opise poslova, instrukcije i slično. Povezano s formalizacijom ponašanja, strukture koje se više oslanjaju na standardizaciju i koordinaciju nazivaju se birokratskima dok se organizacije koje se oslanjaju na direktni nadzor i međusobne prilagodbe nazivaju organskima. Trening i indoktrinacija opisuje se kao parametar kojim su vještine i znanja unutar organizacije standardizirana, kroz opsežan edukacijski program. Pod grupiranjem jedinica, Mintzberg podrazumijeva načine na koje su pozicije u organizaciji okupljene u jedinice i potom jedinice u složenije jedinice i funkcije pod nadzorom strateškog vrha. Veličina jedinica, odnosno raspon kontrole, određuje broj pozicija i podjedinica koje su grupirane u jedinstvenu cjelinu. Decentralizacija, odnosno razina do koje je moć nad odlučivanjem u organizacijama raspršena među članovima dijeli se u dva smjera, vertikalna decentralizacija – razina do koje je moć formalnog odlučivanja delegirano na niže razine autoriteta te horizontalna decentralizacija – razine do koje se moć raspršuje izvan direktnog lanca autoriteta. Starost i veličina utječu na organizacije na način da što su one veće i/ili starije njihova formalizacija je veća, odnosno u slučaju mlađih i manjih organizacija formalizacija je manja. Tehnički sistemi utječu na organizacije na sličan način kao i starost i veličina, tako da se s razvijenijim tehničkim sustavima stvara veća formalizacija organizacije. Faktori moći utječu na strukturu organizacije na način da potreba za moći različitih članova unutar i izvan organizacije može utjecati na distribuciju autoriteta odlučivanja (Mintzberg, 1980.).

S obzirom na navedene osnovne dijelove organizacije i parametre dizajna organizacija, Mintzberg (1980.) postavlja 5 tipova organizacijskih struktura koji su naveliko prisutni u praksi. Prvi tip je jednostavna organizacijska struktura koju karakterizira manjak tehnostrukture, malo pomoćnog osoblja te labava podjela rada, minimalna razlika između jedinica i mala središnja linija. Unutar takve strukture ponašanje nije formalizirano te aktivnosti poput planiranja i treninga su od minimalne koristi. Odlučivanje je centralizirano i najčešće u rukama jedne osobe (poduzetnika-menadžera), odnosno strateški vrh je ključni dio strukture dok je operativna jezgra organski građena. Grupiranje u jedinice nije čvrsto zadano, dok se komunikacijski tokovi najčešće kreću od poduzetnika-menadžera ka svima ostalima. Odlučivanje je neformalno, s centralizacijom moći u jednoj osobi, što omogućuje brze

reakcije na promjene. Kao primjer za jednostavnu strukturu, Mintzberg navodi poduzetničku organizaciju koja je agresivna i često inovativna te konstantno traga za riskantnim okruženjem te poduzetnik-menadžer ne dopušta pretjeranu birokratizaciju koja bi mu usporila odlučivanje. Drugi tip organizacijske strukture je mehanicistička (engl. *Machine Bureaucracy*) koja je visoko specijalizirana, ima rutinske operativne zadatke, izrazito formalizirane procedure i velike jedinice unutar operativne jezgre, relativno centraliziranu moć odlučivanja uz ponešto upotrebe sistema akcijskog planiranja i razrađenu administrativnu strukturu s jasnom razlikom između linija i osoblja. U takvom tipu organizacijske strukture značajnu ulogu ima tehnostruktura, odnosno analitičari koji standardiziraju procese unutar organizacije. Mintzberg navodi da se mehanicistička organizacijska struktura najčešće nalazi u starijim organizacijama, koje imaju dovoljno veliki opseg operacija koji omogućuje ponavljanje i standardizaciju te dovoljno staru organizaciju da su se standardi mogli postaviti. Treći tip organizacijske strukture je profesionalna birokratizacija. U njima se omogućuje birokratizacija bez centralizacije, odnosno ponašanja unutar strukture su standardizirana od strane koordinirajućeg mehanizma koji omogućuje decentralizaciju. Unutar takvih organizacija zapošljava se visoko specijalizirane radnike, poput učitelja i socijalnih radnika, u operativnu jezgru te im se daje značajna autonomija u obavljanju posla. Četvrti tip organizacijske strukture Mintzberg naziva divizijskim, koji sam po sebi nije potpuna struktura nego se nalazi kao suprastruktura. Takva struktura je tržišno bazirana, u kojoj centralno sjedište nadzire skup divizija koje samostalno uslužuju svoja tržišta. Peti tip organizacijske strukture Mintzberg naziva adhokracija (engl. *Adhocracy*) koja se značajno razlikuje od prethodnih s obzirom da je to organska struktura s vrlo malo formalizacije ponašanja, opsežnim horizontalnim specijalizacijama poslova, tendencijom grupiranja profesionalaca u funkcionalne jedinice, odnosno projektne timove orijentirane tržištu. Sami timovi nalaze se na različitim mjestima unutar organizacije i uključuju različite kombinacije linijskih menadžera i osoblja te operativnih eksperata. Adhokracija daje kvazi-formalni autoritet osoblju i time zamućuje razliku između menadžera i osoblja te se intenzivno oslanja na matrične strukture, kombinirajući funkcijske i tržišne osnove za grupiranje. Mintzberg navodi primjere konzultantskih ureda i naprednih industrija poput svemirske kao česte korisnike ovakvog tipa strukture. Radi ranjivosti takvih organizacija zbog ovisnosti o projektima, u prosjeku su to vrlo mlade organizacije koje ili brzo umiru ili se radi veće sigurnosti u kasnijim fazama pretvaraju u birokratske kako bi izbjegle neizvjesnost (Mintzberg, 1980.).

Prethodno navedena Mintzbergova saznanja su široko prihvaćena u teoriji i praksi te je on jedan od citiranih znanstvenika na području organizacijskog dizajna, ali s obzirom da su njegove tvrdnje iznesene prije skoro četrdeset godina, u proteklom razdoblju došlo je do novih saznanja i trendova koji su se značajnim dijelom temeljili na već iznesenom. Veličina organizacija i jedinica se smanjila, više razmjene unutar organizacija je tržišno orijentirano dok se hijerarhijski mehanizmi sve više koriste u tržišnim transakcijama (Zenger, Hesterly, 1997.). Također, isti autori navode kako je povećana lakoća selektivne intervencije podržala niz organizacijskih inovacija s jasnom temeljnom sličnošću; raščlanjene strukture na male, visoko autonomne jedinice kojima se upravlja hibridnim miksom tržišnih i hijerarhijskih elemenata dok tehnologija i organizacijska inovacija olakšavaju infuziju tržišta unutar hijerarhije omogućavajući organizacijama da lakše konfiguriraju, mjere i nagrađuju svoje male podjedinice. Nadalje, tehnološke i administrativne inovacije su ubrzale infuziju hijerarhijskih elemenata, poput nadzora, baratanja nagradama, naređivanjem i bogatom komunikacijom, na tržišta. Pojedini autori pak navode da novi načini organizacije rada jednostavno predstavljaju hibridne oblike diskretnijih organizacijskih tipova poput tržišta i hijerarhije (Foss, 2003.). Osim navedenog, od trendova je još važno istaknuti povezivanje organizacija s potrošačima pa se tako sve više koriste vrijedni uvidi, ideje, resursi i znanje dobiveno od samih potrošača, odnosno organizacijski oblici postaju sve više otvoreni prema van (Felin, Lakhani, Tushman, 2017.).

2.2. Pojmovno određenje ambideksterne organizacije i organizacijske strukture

Jedna od zasigurno modernijih organizacijskih struktura je i ona ambideksterne organizacije koja je tek krajem 20. stoljeća postala popularna u akademskim krugovima. Kauppila (2010.) navodi kako su znanstvenici pokazali povećani interes za organizacijskom ambideksternošću od Duncanovog rada iz 1976., da bi zanimanje značajno poraslo nakon značajnog dijela Marcha iz 1991. u kojem je postavio temelje ambidekternosti koja se u godinama nakon toga proučava. Tushman i O'Reilly su naknadno, 1996., uveli ideju dvostrukih struktura za eksploraciju i eksploataciju, koje su integrirane pri vrhovnom menadžmentu (Kauppila, 2010.). March je 1991. tvrdio da je temeljni izazov s kojim se organizacije susreću taj što

moraju u istom trenu koristiti postojeća sredstva i sposobnosti te osigurati dovoljno istraživanja i novih znanja kako s promjenama na tržištima i u tehnologiji ne bi postali nevažne te da je poteškoća u tome postići ravnotežu jer postoji pristranost u korist eksploatacije s obzirom na veću sigurnost kratkoročnog uspjeha dok u dugom roku onda organizacije postaju ranjivije (O'Reilly, Tushman, 2013.). Prema Marchu, postoje dvije krajnosti, eksploatacija i eksploracija, gdje eksploracija angažira pojedince i organizacije u potrazi, istraživanju, preuzimanju rizika, igri, otkrivanju, inovaciji i varijaciji, eksploatacija povećava produktivnost i efikasnost kroz izbor, izvršavanje, poboljšavanje, implementaciju i uklanjanje varijacije (Lavie, Stettner, Tushman, 2010.). Lavie, Stettner i Tushman (2010.) predlažu povezivanje eksploatacije s izgradnjom na bazi postojećeg znanja u organizaciji, odnosno eksploatacija je prema njima povezana s razvojem organizacije ako on prati postojeću tehnološku putanju i organizacija koristi svoje postojeće vještine i sposobnosti, dok eksploraciju povezuju s odmakom od postojećih znanja i vještina organizacije koji može biti povezan s novih tehničkim vještinama, tržišnom ekspertizom ili vanjskim vezama. Lubatkin i suradnici (2006.) pak navode kako eksploatacija uključuje upotrebu eksplicitnih baza znanja, kako bi kroz njihovu internalizaciju i kombiniranje bilo moguće ostvarivati inkrementalna poboljšanja postojećih tehnoloških ili tržišnih putanja, odnosno namjera eksploatacije je da odgovori trenutnim uvjetima tako da se postojeće tehnologije prilagode i dalje zadovolje potrebe postojećih potrošača, dok suprotno tome, eksploracija je namijenjena da odgovori i vodi latentne trendove kreirajući inovativne tehnologije i nova tržišta.

Tabela 1: Determinante eksploatacije i eksploracije

Usklađivanje s:	Eksploatacija	Eksploracija
Strateška namjera	trošak, profit	inovacija, rast
Kritični zadaci	operacije, efikasnost, inkrementalne inovacije	prilagodljivost, novi proizvodi, značajna inovacija
Kompetencije	operacijske	poduzetničke
Struktura	formalne, mehanicističke	prilagodljiva, labava
Kontrola, nagrade	marže, produktivnost	miljokazi, rast
Kultura	efikasnost, niski rizik, kvaliteta, potrošači	preuzimanje rizika, brzina, fleksibilnost, istraživanje
Uloga lidera	autoritativno, top-down	vizionarsko, uključeno

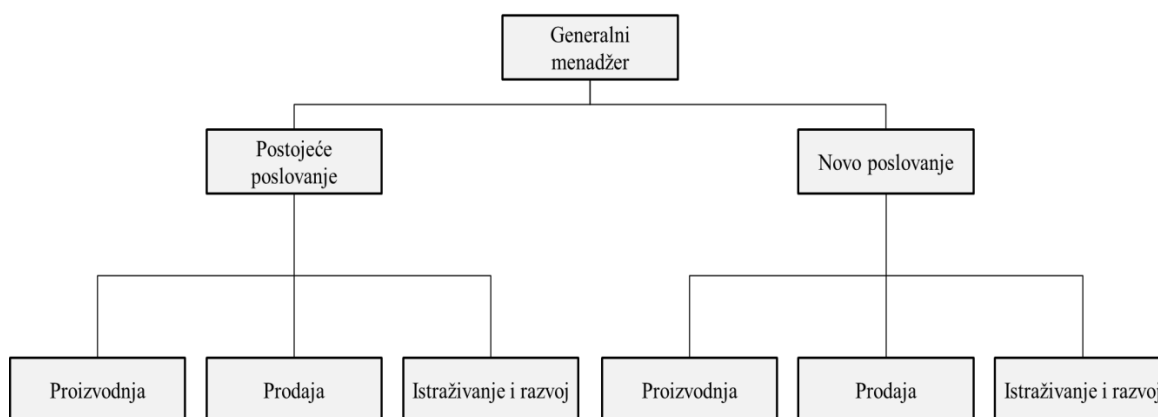
Izvor: O'Reilly, Tushman (2004.), obrada autora

S obzirom na navedeno, eksploatacija primarno uključuje učenje kroz top-down proces, u kojem vrhovni menadžeri nastoje institucionalizirati rutine i ponašanja koja su najbolje prilagođena za poboljšanje postojećih kompetencija dok suprotno, eksploracija generalno uključuje bottom-up proces učenja, u kojem su vrhovni menadžeri motivirani da napuste stare rutine i posvete se novom smjeru. Za razliku od eksploatacije, navedeno kod eksploracije zahtijeva razvoj novih vještina i interne procese selekcije od kojih se očekuje da donesu dovoljnu raznolikost autonomnih strateških inicijativa, odnosno eksperimenata s novim vještinama ili tržišnim prilikama koji su motivirani pomacima na tržištima (Lubatkin, 2006.). Zbog toga su eksploativne jedinice veće i više centralizirane, s uskim kulturama koje su fokusirane na maksimiziranje efikasnosti i kontrole kroz procesni menadžment dok su eksploratorne jedinice obično male i decentralizirane s opuštenim kulturama i fleksibilnim procesima. S obzirom na razlike u jedinicama, fundamentalno različiti konteksti učenja su fizički i kulturno odvojeni jedan od drugog kako bi se izbjegla kulturna i proceduralna prelijevanja (Lavie, Stettner, Tushman, 2010.).

Proizvodi i usluge koji nastaju kao rezultat rada eksploativnih i eksplorativnih jedinica često su direktna konkurencija jedni drugima, kako za interne resurse unutar organizacije, tako i na tržištu. Vanjska potražnja na tržištu i povijesno ukorijenjena inercija potpomažu postojeće proizvode nauštrb inovacije. Ako ih se ne kontrolira, inercijske sile zarobljavaju organizaciju unutar svojih postojećih kompetencija te se često uspješne organizacije nađu u problemima kada s vremenom eksploatacija izgura eksploraciju (Smith, Tushman, 2005.). Levinthal i March (1993.) tvrde kako i potpuna eksploracija nije dobra za organizacije jer će vjerojatno patiti od činjenice da nikada neće ostvariti povrat na svoje znanje.

Na teoretskoj razini dakle, ambideksterna struktura omogućava te dvije krajnosti i omogućava istovremeno funkcioniranje obje, odnosno dozvoljava razmjenu važnih resursa iz tradicionalnih jedinica – novca, talenta, znanja, kupaca, itd., dok organizacijska odvojenost osigurava da specifični procesi, strukture i kulture novih jedinica nisu pod dojmom uobičajenog poslovanja. U isto vrijeme štiti se postojeće jedinice od distrakcija koje iziskuju pokretanja novih poslova, odnosno postojeće jedinice mogu svu pažnju i energiju posvetiti na poboljšavanje svojih operacija i proizvoda te na bolje usluživanje svojih kupaca (O'Reilly, Tushman, 2004.).

Slika 1: Ambideksterna organizacijska struktura



Izvor: O'Reilly, Tushman (2004.), obrada autora

Kao glavne faktore koji utječu na eksploraciju i eksploataciju unutar organizacija i njihove pozicije, Lavie, Stettner i Tushman (2010.) navode faktore iz okruženja poput dinamike, egzogenih šokova i natjecateljskog intenziteta te organizacijske povijesti kroz starost, veličinu, oskudne resurse, apsorpcijske sposobnosti, organizacijsku strukturu i kulturu, ali i pristranosti menadžera. Na primjeru autori navode kako novije organizacije imaju nedostatak specifičnih resursa, ograničenu bazu potrošača te tek postavljaju organizacijske uloge i strukturne odnose, što ih navodi da investiraju u eksploraciju, dok suprotno tome, starije organizacije nailaze na probleme kada žele pratiti tehnološke napretke jer su ovisne o već postavljenim rutinama i vještinama, što samo od sebe stvara inercijski pritisak i dovodi takve organizacije prema eksploataciji. Također, dionici mogu utjecati na izbor eksploatacije s obzirom da većinom favoriziraju organizacije koje pokazuju racionalnost, odgovornost i pouzdanost koje se temelje na postojećim rutinama, strukturama i vještinama dok averzija menadžera prema riziku također pomiče organizacije prema eksploataciji.

Vjerojatno najvažnija razlika između ostalih organizacijskih struktura te ambideksterne organizacijske strukture jest što u slučaju ambideksterne organizacije postoji jasna distinkcija između postojećeg poslovanja i budućeg, novog poslovanja, ali i jasna povezanost između tih poslova kroz usko integrirani tim vrhovnih menadžera koji služe kao spona te na sebe preuzimaju najveću odgovornost. O'Reilly i Tushman (2004.) tvrde kako takva pozicija menadžera predstavlja jedan od najvećih menadžerskih izazova, odnosno da se od menadžera očekuje simultano istraživanje novih prilika dok se pokušavaju iskoristiti postojeće sposobnosti. Točnije, u jednoj osobi očekuje se kombiniranje atributa rigoroznog rezača troškova i slobodnog poduzetnika paralelno zadržavajući objektivnost koja je potrebna

kako bi se donosile teške odluke raspodjele resursa. Od menadžera se zapravo zahtijeva da odrede pravi balans, odnosno miks između eksploatacije i eksploracije te da pritom mogu jasno unapređivati oba segmenta poslovanja i dugoročno razvijati poduzeće, što je mentalno vrlo zahtjevno (Lavie, Stettner, Tushman, 2010.) te stavlja premiju ne samo na menadžere nego i na cijeli tim vrhovnih menadžera koji može upravljati navedenim kontradikcijama (Tushman, et al., 2010.). Kako bi to ostvarili, menadžeri trebaju kreirati i održavati složeni organizacijski dizajn koji ne samo da omogućava organizacijama da se istovremeno učinkovito uključe u potencijalno sukobljene aktivnosti, već im omogućava i kombiniranje kratkoročnog usklađivanja s dugoročnom prilagodljivošću (Rothaermel, Alexandre, 2009.). Što je prema Lubatkinu i suradnicima (2006.) još i teže u malim i srednjim poduzećima jer ima manje hijerarhijskih razina što dovodi do toga da je vrlo izgledno da vrhovni menadžeri moraju odrađivati i strateške i operativne funkcije unutar organizacije te su na taj način direktno izloženi kontradiktornosti eksploatacije i eksploracije.

Osim složenog organizacijskog dizajna, menadžeri trebaju stvoriti i jasne i sažete ciljeve za oba dijela organizacije kako bi jednako motivirala na uspjeh i eksploraciju i eksploataciju (Smith, Tushman, 2005.). Također, potrebno je stvoriti organizacijski identitet koji će onda pružati članovima organizacije pogled na organizacijske ciljeve, misiju i dominantnu logiku koja vodi eksplorativne i eksploatacijske aktivnosti (Lavie, Stettner, Tushman, 2010.). Kao vrhunac zajedničkog usmjerenja, menadžeri trebaju stvoriti jasnu i uvjerljivu viziju, koja će biti prihvaćena i poduprijeta od strane kompletnog vrhovnog menadžmenta (O'Reilly, Tushman, 2004.).

S razvojem znanja i povećanim istraživanjem na temu ambideksternosti, razvila su se tri pristupa ambideksternosti koja su detaljno istražena, a to su: sekvencijalna, strukturalna i kontekstualna ambideksternost. Sekvencijalna ambideksternost pokriva stajalište da organizacije mogu prilagoditi svoje strukture tako da odražavaju promijenjene uvjete u okolini ili strategije. Strukturalna ambideksternost je drugi način koji se predlaže za uravnoteženje kompromisa između eksploracije i eksploatacije kroz istodobnu obavljanje oba poslovanja korištenjem zasebnih jedinica. Kontekstualna ambideksternost podrazumijeva da unutar poslovne jedinice postoji kapacitet da se kombinira eksploracija i eksploatacija (O'Reilly, Tushman, 2013.).

2.3. Uloga ambideksternih organizacija u uspješnosti poduzeća

Samo 160 od 1008 poduzeća preživjelo je od 1962. do 1998. godine. Trećina poduzeća u Fortune500 iz 1970. više nije postojala u 1983. godini. Studije organizacijske smrtnosti procijenile su da velika poduzeća imaju očekivano trajanje u rasponu od 6 do 15 godina. Većina poduzeća osnovanih unutar jedne industrije ne preživljavaju na dugi rok (O'Reilly, Harreld, Tushman, 2009.). Navedeni zaključci istraživanja upućuju na to da tradicionalne organizacije nemaju velike šanse dugoročnog funkcioniranja u kompetitivnom svijetu. Odnosno, prema riječima Charlesa Darwina, ni snaga ni inteligencija ne jamče preživljavanje. Samo prilagodba to može učiniti, bilo za organizacije ili floru i faunu (O'Reilly, Harreld, Tushman, 2009.). U tom pogledu, March (1991.) je predlagao kako je održivost organizacijskih performansi povezana s mogućnosti organizacije da balansira eksploataciju i eksploraciju, odnosno bude ambideksterna.

Paradoks navedenog je u tome što su eksploatacija i eksploracija kontradiktorne aktivnosti, ali organizacija nije u mogućnosti ostvarivati očekivane performanse bez uključivanja u oboje (Lavie, Stettner, Tushman, 2010.). Kao negativna strana tog paradoksa je što organizacije koje su odvojene na dvije domene (eksploataciju i eksploraciju) mogu doživjeti pad performansi zbog općih troškova povezanih s odvajanjem resursa na obje jedinice (Van Looy, Martens, Debackere, 2005.).

Osim same odluke organizacija da postanu ambideksterne, važne su i okolnosti oko organizacija, odnosno vanjski čimbenici. Lavie, Stettner i Tushman (2010.) tako ističu nekoliko faktora koji utječu na ambideksterne organizacije i one koje to planiraju postati. Naime, organizacije koje vrše eksploataciju imaju bolje šanse za preživljavanje u stabilnim okruženjima, dok turbulentna vremena favoriziraju organizacije koje mogu brzo iskoristiti mogućnosti u nastajanju i napustiti postojeće sigurnosti. U turbulentna vremena ubrajaju se egzogeni šokovi koji su potaknuti nepredvidljivim događajima, poput deregulacije ili tehnoloških proboja. Takve revolucionarne transformacije često naprave postojeće tehnologije i vještine unutar organizacija zastarjelima. Revolucionarne transformacije događaju se u vremenima konkurentskih pritisaka, odnosno kada je povećan broj konkurenata koji posljedično vodi do rezanja cijena, manjih marža te manje zabušavanja unutar organizacija. Suprotno tome, poticaji za eksploataciju dominiraju kada je konkurentska tenzija prigušena i kada organizacije ostvaruju razumne povrate na investicije kroz postojeće proizvode, usluge i

tehnologije (Lavie, Stettner, Tushman, 2010.). I drugi radovi ukazuju na važnost okruženja na ambideksternost organizacija, odnosno da je ambideksternost više korisna u uvjetima neizvjesnosti (vidjeti O'Reilly i Tushman, 2013.).

Lavie, Stettner i Tushman (2010.), osim okruženja, kao bitan faktor koji utječe na ambideksternost i uspješnost poduzeća navode veličinu organizacija te navode oprečne nalaze istraživanja koja s jedne strane zaključuju da balansiranje eksploatacije i eksploracije raste s povećanjem veličine organizacije, dok s druge strane pojedina istraživanja pokazuju kako se s povećanjem organizacija smanjuje efikasnost balansiranja. Iz druge perspektive, O'Reilly, Harreld i Tushman (2009.) zaključuju kako mala, odnosno nova poduzeća moraju staviti izbor života ili smrti na jedan eksperiment te je zato mala veličina gotovo uvijek korelirana s visokim stopama propadanja, odnosno velika većina malih poduzeća posluje na premaloj, neučinkovitoj razini te vrlo brzo propadaju. S druge strane, velika poduzeća mogu istovremeno provoditi nekoliko eksperimenata u kojima neuspjeh ne ugrožava sigurnost samog poduzeća, a u isto vrijeme može povećati znanje unutar istog, odnosno velika poduzeća ne susreću se s istim zaprekama prilikom ambideksternih aspiracija kao mala poduzeća (O'Reilly, Harreld, Tushman, 2009.).

Tushman i suradnici (2010.) su u svojem longitudinalnom i dubinskom istraživanju na vrhunskim američkim poduzećima potvrdili neke od prethodnih tvrdnji te dokazala povezanost ambideksternosti s uspješnosti poduzeća. Naime, prema njihovom istraživanju, nema značajnih razlika u ishodima inovacija između organizacija koje su se fokusirale na jednu inovaciju u usporedbi s onima koje su pokrenule nekoliko inovacija. Također, ni diskontinuirane epizode inovacija nisu više ni manje uspješne od arhitekturnih epizoda inovacije. Nadalje, nema značajnih razlika između inovacijskih epizoda usmjerenih na postojeće potrošače i onih na nova tržišta. Jedino što je u istraživanju ustanovljeno da ima pozitivan utjecaj na provođenje inovacija je ambideksterni dizajn. Odnosno, istraživanje pokazuje da ambideksterni dizajn organizacija je značajno efektivniji u izvršenju inovacija nego što su to funkcijski, međufunkcijski ili *spinout* dizajni. Također, tranzicije ka ambideksternim dizajnu bile su povezane sa značajno povećanim ishodima inovacija, dok se pomaci od ambideksternog dizajna povezuju sa smanjenjem ishoda inovacija. Dodatno, ambideksterni dizajn je pozitivno povezan i s kontinuiranim performansama postojećih proizvoda, dok su za usporedbu kod funkcijskih, međufunkcijskih i *spinout* dizajna performanse postojećih proizvoda inverzno povezane s izvođenjem inovacija, odnosno u takvom dizajnu organizacije nije moguće istovremeno odrađivati obje stvari. Osim samog

ambideksternog dizajna, Tushman i suradnici (2010.) navode kako je ambideksteri menadžer, osoba na visokoj poziciji unutar poslovne jedinice ili organizacije (generalni direktor, predsjednik ili CEO), centralna figura koja je povezivala eksploraciju i eksploataciju. Ambideksteri menadžer je imao vlastito osoblje i resurse te je njegova jedinica za inovacije iskoristavala resurse iz postojeće organizacije putem ciljanih mehanizama integracije. Osim navedenog, od iznimne važnosti pokazala se i povezanost ambideksternog menadžera s generalnim menadžerom unutar postojeće organizacije, odnosno redovni sastanci između tih dviju pozicija su pozitivno utjecali na uspješnost provođenja inovacija i performanse poduzeća. Također, ovo istraživanje je potvrdilo i već navedene tvrdnje kako su menadžeri primorani učiti o kompleksnim organizacijskim oblicima u kriznim uvjetima, dok se suprotno tome, odmaci od ambideksternog dizajna događaju u kontekstu stabilnih i/ili poboljšavajućih inovacijskih ishoda (Tushman, et al., 2010.).

Presjek radova na temu ambideksternosti koji su napravili O'Reilly i Tushman (2013.) pokazuje kako je ambideksternost pozitivno povezana s povećanjem prodaje, subjektivnim ocjenama performansi, inovacijama, tržišnim valuacijama mjerenima Tobinovima Q i preživljavanjem organizacije. Studije koje prikazuju dokumentirale su efekte ambideksternosti na organizacije, poslovne jedinice, projekte i na individualnoj razini te iako sama organizacijska ambideksternost može biti duplikativna i neefikasna, ima pozitivan efekt na poslovanje organizacije. Nadalje, O'Reilly i Tushman posebno izdvajaju istraživanje koje je proučavalo više od 500 organizacija kroz četverogodišnje razdoblje te je ustanovljeno da ambideksternost ima pozitivan efekt na rast organizacija te da su kroz desetogodišnje razdoblje organizacije s većim tehnološkim mogućnostima imale veće koristi od ambideksternosti.

Osim agregiranih istraživanja na većim uzorcima, u istraživanjima se često spominju i neka od danas važnih i većih poduzeća na svijetu. Tako Tushman i suradnici (2010.) detaljno opisuju poduzeće USAToday koje je iz nakladničkog poslovanja preko ambideksterne strukture razvilo online medij paralelno uz nastavak nakladničkog poslovanja. To je postiglo tako da je izgradilo fundamentalno drugačiji set struktura, uloga, nagrada i kulturu koja je bila posvećena instantnim vijestima. Samo online poslovanje bilo je na svom katu, fizički odjeljeno od novinskog poslovanja. Kako bi se održala veza između dva različita poslovanja, redoviti sastanci su održavani na najvišoj razini, dok je vodstvo poduzeća imalo novo nagrađivanje koje se baziralo i na online i na novinskom poslovanju. Osim USAToday,

Tushman i suradnici (2010.) navode kako je prijelaz na ambideksterni dizajn bio povezan s rapidnim napretkom u HP-ovom starom proizvodu, ali i inovaciji.

O'Reilly, Harreld i Tushman (2009.) u svom radu detaljno opisuju kako je IBM kroz program Nove poslovne mogućnosti (engl. *Emerging Business Opportunities* – EBO) ostvario značajan rast i omogućio inovacije koje su omogućile milijarde dolara novih prihoda. Navedeni ključni principi za uspjeh EBO-a su: sponzorstvo od strane vrhovnog menadžmenta koje je aktivno i često, posvećeno vodstvo visoke kvalitete, disciplinirani mehanizmi za usklađivanje između kompanije, nadgledani i ograničeni resursi kako bi se izbjeglo preuranjene rezove, radnje povezane s kritičnim *milestoneima*, brzi start i brzo zaustavljanje. Sami primjer IBM-a prikazuje kako se nove poslovne jedinice sistematično stvaraju, testiraju i obzirom na rezultate rastu ili gase, ilustrira kako izbor na više razina može pomoći organizacijama da se prilagode novim tržištima (O'Reilly, Harreld, Tushman, 2009.). Osim ključnih principa, autori navode slične preduvjete kao i kod USA Today, odnosno unutar samih EBO-a za uspjeh je bilo potrebno da se postave organizacije s različitim ljudima, sustavima, strukturama, nagradama i kulturom od onih u regularnom poslovanju IBM-a. Također, kao kritičan faktor uspjeha navodi se potpora vodstva organizacije.

Sve navedeno ukazuje kako ambideksterna organizacija ima značajne pozitivne utjecaje na uspješnost poduzeća, posebice u dugom roku. S obzirom na tek nedavni razvoj saznanja o ambideksternim organizacijama i njihovom utjecaju na poduzeća, koji je snažnije započeo u devedesetim godinama 20. stoljeća, za očekivati je kako će u budućnosti sve više pažnje biti posvećeno formiranju organizacija u ambideksternom obliku, pogotovo ako se njihova dugoročna uspješnost uspije dokazati iznova u promijenjenim okolnostima poslovanja.

3. UMJETNA INTELIGENCIJA I NJEN UTJECAJ NA POSLOVANJE

3.1. Pojmovno određenje umjetne inteligencije

Kao preduvjet za razvoj umjetne inteligencije, prethodno je trebalo doći do razvoja računala. Računala su se počela razvijati od 1939. s dolaskom Mark I, prvog modernog računala, i ENIAC-a 1943., prvog elektroničkog računala bez pomičnih dijelova. Rezultat napretka u računalima koji je pokrenut omogućio je kasniji razvoj digitalnih računala sa značajnim mogućnostima za računanje, s čime je počelo razdoblje računala (Brynjolfsson, Hitt, 2000.).

Sama umjetna inteligencija počela se razvijati na temeljima razvoja računala prije otprilike 60 godina s kreiranjem pojma „umjetna inteligencija“ (engl. *artificial intelligence*) na radionicama na Dartmouth College-u u Sjedinjenim Američkim Državama koje je inicirao John McCarthy 1956. godine. Sama definicija koju su znanstvenici tada postavili odnosila se na sposobnost strojeva da razumiju, razmišljaju i uče na sličan način kao ljudska bića, ukazujući na mogućnost korištenja računala za simulaciju ljudske inteligencije. Od tada, umjetna inteligencija doživjela je 60 godina stalnog razvoja uz značajna napredovanja i zapreke. Od 1970-ih, umjetna inteligencija raširila se u istraživačka područja koja uključuju mehaničko dokazivanje teorema, strojni prijevod, ekspertne sustave, teoriju igara, prepoznavanje uzoraka, strojno učenje, robotiku i inteligentno upravljanje (Pan, 2016.).

Putanja razvoja umjetne inteligencije bila je povezana s razvojem informatičkih tehnologija, odnosno prvi val razvoja umjetne inteligencije bio je koreliran s prvim valom IT-a, tijekom 1960-ih i 1970-ih, u kojem se radi razvoja tehnologija omogućilo automatiziranje pojedinačnih aktivnosti u lancu vrijednosti, od obrade narudžbi i plaćanja računa do računalnog planiranja i planiranja proizvodnih resursa (Porter, Heppelmann, 2014.).

Prema Panu (2016.), prvo veliko usporavanje razvoja umjetne inteligencije (od tri koja su se dogodila) započeto je 1973. izvješćem Jamesa Lighthilla, objavljeno u Engleskoj. Izvješće je raspravljalo o konceptu automata, robota i središnjeg živčanog sustava kao područja temeljnog istraživanja umjetne inteligencije i zaključilo je kako istraživanje automatizacije i

središnjeg živčanog sustava ima vrijednosti, ali kako je razvoj istoga bio razočaravajući dok istraživanje o robotima nije imalo nikakvu vrijednost, a razvoj je bio spektakularno razočaranje i kako ga zbog toga treba otkazati. Drugo usporavanje odnosilo se na neuspjeli razvoj inteligentnog računala u Japanu. U 1982., Ministarstvo za međunarodnu trgovinu i industriju Japana započelo je projekt pete generacije računala u nadi da će stvoriti nešto što ima sposobnost zaključivanja i obrade znanja. Do 1992., projekt je potrošio 850 milijuna dolara, bez napretka u ključnim tehnološkim problemima. Ovaj neuspjeh pružio je uvid da razvoj umjetne inteligencije trebao biti vođen razvojem inovacija i softvera, s hardverom koji se koristi za podršku operaciji (Pan, 2016.). Samo ulaganje japanskog Ministarstva bilo je dio drugog vala razvoja informatičkih tehnologija i transformacija koje su bile pogonjene razvojem interneta, koji je to omogućavao svojom jeftinom i sveprisutnom povezanošću u 1980-ima i 1990-ima. I prvi i drugi val razvoja informatičkih tehnologija i posljedično umjetne inteligencije, usprkos nekim neuspjelim pokušajima, dovela su do velikog povećanja produktivnosti i rasta u cijelom gospodarstvu primarno kroz transformaciju lanca vrijednosti, dok su proizvodi uglavnom ostali nepromijenjeni (Porter, Heppelmann, 2014.). Kao treće veliko usporavanje, Pan (2016.) navodi istraživanje na Sveučilištu Stanford koje je započeto 1984. i za cilj je imalo ručno izgraditi enciklopediju znanja (skraćenice *Cyc*) koja bi sadržavala svo ljudsko zdravorazumsko znanje. Razvoj *Cyc*-a počeo je usporavati do kraja 1990-ih, usprkos mogućnosti povezivanja s vanjskim bazama znanja, zbog toga što su internet i veliki podaci (engl. *big data*) posjedovali više snage radi razvoja tražilice (engl. *search engine*). Pad *Cyc*-a nastavio se do točke bez povratka, ali je za daljnji razvoj ostala pouka da je neisplativo naučiti ogromne količine znanja preko ljudskog znanja, umjesto toga znanje bi trebalo razvijati automatski iz okoline (Pan, 2016.).

Razdoblja između velikih usporavanja u razvoju umjetne inteligencije, popularno su nazivana „proljećima“ te su usko povezana s ekonomskim razvojem s obzirom da su troškovi poput istraživanja značajno rezani u doba ekonomskog usporavanja i povećanja kamatnih stopa. Osim navedenog, problemi u razvoju umjetne inteligencije bili su uzrokovani i s nekompatibilnosti umjetne inteligencije s varijacijama u informacijskom okruženju. Razvoj umjetne inteligencije vođen je istraživanjem i informacijskim okruženjem s pripadajućim društvenim ciljevima. Iako je oboje važno, društveni ciljevi uvijek imaju jaču pokretačku snagu (Pan, 2016.).

U sadašnje vrijeme, na većinu modernih industrija značajno utječe informatizacija, što je izravno povezano s velikim troškovnim uštedama u koordinaciji, komunikaciji i obradi

informacija putem računala te dolazi do restrukturiranja gospodarstava (Brynjolfsson, Hitt, 2000.). Osim ušteda u troškovima, Porter i Heppelmann (2014.) napominju kako je do niza inovacija došlo radi napretka u performansama, smanjenju prosječne veličine i energetskej efikasnosti senzora i baterija; vrlo kompaktne i jeftine procesne snage i pohrane podataka (što omogućuje da je isplativo postavljati računala unutar proizvoda, engl. *smart products*); jeftinih priključaka za povezivanje te sveprisutna, jeftina bežična povezanost; alata koji omogućuju brz razvoj softvera; analitike velikih podataka (engl. *big data analytics*); te novim internetskim sustavom registracije IPv6 koji omogućuje otvaranje do 340 bilijuna bilijuna bilijuna potencijalnih novih internetskih adresa za individualne uređaje s protokolima koji podržavaju veću sigurnost, pojednostavljuju predaju za vrijeme kretanja uređaja preko mreža te dozvoljavaju uređajima da autonomno zatraže adrese bez IT podrške. Detaljnije, Pan (2016.) navodi kako je informacijsko okruženje oko razvoja umjetne inteligencije duboko promijenjeno što je dovelo do nove evolucijske faze koju on naziva umjetna inteligencija 2.0 (engl. *AI 2.0*), odnosno pojava novih tehnologija je zaslužna za promicanje umjetne inteligencije u novu fazu. Pan dalje navodi kako su vanjske sile koje su utjecale na razvoj nove faze umjetne inteligencije potekle iz četiri područja. Prvenstveno, informacijsko okruženje u 21. stoljeću drastično se promijenilo paralelno s popularnošću mobilnih terminala. Nadalje, svijet se razvio iz binarnog prostora (fizika i ljudsko društvo) u ternarni prostor (*cyber*, fizika i ljudsko društvo). Društvene potrebe za umjetnom inteligencijom brzo rastu, što rezultira u drastičnim promjenama u istraživanju umjetne inteligencije, koje se premješta iz pozicije u kojoj je primarno bilo vođeno akademskom znatiželjom u poziciju gdje je vođeno potražnjom koja je fokusirana izvan akademskih krugova. Stoga, mnogo poduzeća je aktivno promoviralo nova istraživanja umjetne inteligencije. Treće, ciljevi umjetne inteligencije pretrpjeli su velike promjene, mijenjajući se iz potrage za „korištenjem računala za simuliranje ljudske inteligencije“ u: poboljšane hibridne inteligentne sustave koji kombiniraju strojeve i ljude; nove inteligentni sustavi mnoštva (engl. *crowd intelligence systems*) organizirani od strane strojeva, ljudi i mreža; te složenijih inteligentnih sustava. Četvrto, izvori podataka povezani s umjetnom inteligencijom se mijenjaju. Stoga je razvoj umjetne inteligencije povezan s velikim podacima, senzorima i mrežama te unakrsnim medijima, neizbježan trend. S kontinuiranim razvojem računalnih mreža i mobilnih terminala, globalni multimedijiski podaci pokazuju eksplozivni rast. Inteligencija unakrsnih medija stoga predstavlja kamen temeljac umjetne inteligencije, u tome što omogućuje da strojevi prepoznaju svoje vanjsko okruženje (Pan, 2016.).

Trenutno, jedan od segmenata umjetne inteligencije koji se najviše razvija je strojno učenje. Autor (2015.) objašnjava kako strojno učenje primjenjuje statistiku i induktivno obrazloženje za pružanje odgovora na najbolji mogući način gdje su formalna proceduralna pravila nepoznata. Strojno učenje omogućava da u slučaju nemogućnosti inženjera da programiraju stroj da simulira nerutinski zadatak prateći zapisani postupak, je moguće programirati stroj za samostalno savladavanje zadataka koji su izvršili drugi. Procesom izlaganja, treninga i pojačanja, algoritmi strojnog učenja potencijalno mogu zaključiti kako izvršiti zadatke koji su se pokazali zahtjevnima kodificirati s eksplicitnim postupcima. Proces treninga samog sustava bazira se na velikim bazama podataka tzv. „prizemne istine“ (engl. „*ground truth*“) – značajnog broja odabranih primjera označenih predmeta prema kojima algoritam strojnog učenja pokušava zaključiti, npr. koji atributi predmeta čine manje ili više vjerojatno da će objekt biti određen kao stolica. Kada je trening završen, stroj može primijeniti statistički model kako bi pokušao identificirati stolice koje se razlikuju od onih u originalnom skupu podataka za trening. U osnovi, strojno učenje je ateoretska tehnika grube sile koja zahtijeva samo velike baze podataka za trening, veliku moć obrade i sofisticirani softver (Autor, 2015.)

Porter i Heppelmann (2014.) navode kako će u budućnosti, novi skok u produktivnosti u gospodarstvu biti oslobođen s novim i poboljšanim proizvodima i uslugama. Dodatno, oni će ponovno promijeniti lanac vrijednosti, s promjenom dizajna proizvoda, marketingom, proizvodnjom i postprodajom te stvaranjem potrebe za nove aktivnosti kao što su analiza podataka proizvoda i sigurnost. Schildt (2017.) pak navodi kako napredniji algoritmi, uključujući i sustave koji se identificiraju kao umjetna inteligencija, obećavaju povećanje produktivnosti korištenjem računala i podataka za sve složenije zadatke, brže i jeftinije od ljudi. Detaljnije, računala i slični napredniji sustavi su najuspješniji u rutinskim, ponavljajućim zadacima, koji su se tipično kroz povijest vrlo bogato nagrađivali, što je uzrok značajnih ušteda, dok drugo, zadaci koji se odrađuju preko navedenih sustava omogućavaju puno lakše prikupljanje podataka, kako namjerno, tako i kao nusproizvod ostalih zadataka (Bresnahan, Brynjolfsson, Hitt, 2002.). Kako računala postaju jeftinija i snažnija, poslovna vrijednost računala, odnosno tehnologije, je manje ograničena računalnim sposobnostima nego što je ograničena mogućnostima menadžera da inoviraju nove procese, procedure i organizacijske strukture koje će utjecati na iskorištavanje računalnih sposobnosti (Brynjolfsson, Hitt, 2000.). Trenutno to prepoznaju investicijski fondovi i velike tehnološke kompanije, uz vrlo povoljne gospodarske uvjete u posljednjih desetak godina na svjetskim tržištima pa dolazi do velikog broja spajanja i preuzimanja, što u kombinaciji s priljevima

kapitala, za umjetnu inteligenciju znači ubrzavanje integracije s aplikacijama koje ubrzavaju već brzu transformaciju povezanih ekonomija (Pan, 2016.).

Za očekivati je kako će daljnji razvoj tehnologije i povezanih poslovnih procesa dovesti do značajnih promjena u tome kako se poslovi rade i organiziraju. Zadaci koji zahtijevaju prosuđivanje, kreativnost i česte iznimke mnogo je teže informatizirati od dobro definiranih i ponavljajućih zadataka što znači da će i dalje potražnja za uredskim službenicima i sličnim poslovima padati dok će ona za menadžerima i profesionalcima rasti (Bresnahan, Brynjolfsson, Hitt, 2002.). Pan (2016.) tvrdi kako je u specijaliziranim područjima moguća supstitucija rada strojevima, dok za generalnu inteligenciju procjenjuje kako to neće biti moguće u idućih 60 godina zbog toga što je napredak u području automatiziranih inteligentnih strojeva daleko efektivniji, lakši i ekonomičniji. Osim zamjena postojećih zanimanja, prema Porteru i Heppelmannu (2014.), za izgradnju i podršku tehnologiji pametnih proizvoda i strojeva bit će potreban niz novih vještina, odnosno zanimanja poput razvoja softvera, inženjerstva sustava, analize podataka i ekspertize internetske sigurnosti. U daljoj budućnosti, Pan (2016.) očekuje kako će se integrirati prirodna i umjetna inteligencija radi poboljšanja ljudske intelektualne aktivnosti te da će biti usko integrirana u ljudski život (umreženi mediji i autonomni sustavi) do te mjere da postane dio ljudskog tijela (hibridna proširena inteligencija).

3.2. Utjecaj umjetne inteligencije na poslovanje poduzeća

Nedavno istraživanje Acemoglua i Restrepa (2018.) pruža detaljan teorijski uvid iz ekonomske perspektive kako bi umjetna inteligencija, odnosno automatizacija mogla utjecati na poslovanje poduzeća. Njihov teorijski model pretpostavlja kako postoje dva tipa tehnoloških promjena: automatizacija koja dozvoljava organizacijama da zamjene aktivnosti prethodno rađene kroz rad kapitalom, te stvaranje novih zadataka koji omogućavaju zamjenu starih zadataka novim oblicima u kojima rad ima veću produktivnost. Jedan od glavnih faktora koji ima utjecaj na razinu automatizacije je dugoročna stopa kapitala za posudbu, koja ako je vrlo niska u usporedbi s plaćama, neće postojati dovoljno poticaja za stvaranje novih zadataka, i dugoročna ravnoteža uključuje potpunu automatizaciju. Odnosno, efekti

tehnologije na udio rada i plaća, ovise o elastičnosti supstitucije između kapitala i rada. Sama alokacija zadataka između kapitala i rada određena je s raspoloživom tehnologijom te endogenim odabirom organizacije između proizvodnje s kapitalom ili radnom snagom. Prema modelu, kada se ravnotežni raspon zadataka dodijeljenih kapitalu poveća (kao rezultat automatizacije), relativne plaće u odnosu na stopu kapitala i udio radne snage opadaju, a ravnotežna stopa plaća također može pasti. Također, u slučaju da se ravnotežni raspon zadataka alocira na povećanje rada, dolazi do obrnutog rezultata, odnosno podizanja plaća u odnosu na stopu kapitala i povećanje udjela radne snage. To se događa jer je ponuda rada elastična, a automatizacija smanjuje zaposlenost, dok stvaranje novih zadataka povećava zaposlenost. Kroz vrijeme ipak autori predviđaju kako će doći do uravnoteženja rada i kapitala s obzirom da kada faktori postaju jeftiniji, to utječe na raspon zadataka koje organizacije žele automatizirati, odnosno stvaraju se poticaji za organizacije da uvođe tehnologiju kako bi iskoristile faktore intenzivnije. Takvi poticaji podrazumijevaju da se sa smanjenjem efektivnog troška rada u najmanjem zahtjevnim zadacima, automatizacija zapravo nakon određene razine zaustavlja daljnju automatizaciju i stvara samoispravljaću silu prema ravnoteži. Iako oba ishoda u modelu (automatizacija i stvaranje novih zadataka) podrazumijevaju značajan ekonomski rast, imaju vrlo različite implikacije na faktorsku distribuciju prihoda i zaposlenosti (Acemoglu, Restrepo, 2018.).

Istraživanja temeljena na praksi, odnosno rezultatima poslovanja poduzeća koja su implementirala informacijsku tehnologiju, pokazuju kako postoji pozitivna veza između ulaganja u informacijske tehnologije i povećanja u proizvodnji i produktivnosti (Brynjolfsson, Hitt, 2000.). Isti autori navode kako je moguće da su povrati na investicije u tehnologiju značajno viši od onoga što se pretpostavlja u tradicionalnim računanjima povrata. Nadalje, sami pozitivni utjecaj tehnologije, razlaže se na kratki i dugi rok gdje se smatra kako u kratkom roku povrati na investiciju predstavljaju direktne efekte investicija u informacijsku tehnologiju, dok u dugom roku povrati predstavljaju efekte kombiniranja investicija u informacijsku tehnologiju te investicija u organizacijske promjene (Bresnahan, Brynjolfsson, Hitt, 2000.). Navedeno je posebno važno s obzirom da su ekonomisti identificirali umjetnu inteligenciju kao tehnologiju generalne namjene koja će formirati veliki broj industrija i imati utjecaj na rad i vrijednost vještina u kojima se predviđa da će polarizacija u produktivnosti izbrisati prosječnost (Schildt, 2017.).

Na razini industrija, Porter i Heppelmann (2014.) predviđaju kako će radi novih tehnoloških postignuća doći do većih barijera za ulazak u industrije, što će povezano s prednosti prvog

poduzeća u industriji koje će ostvarivati prednosti od rane akumulacije i analize podataka, dovesti do konsolidacije mnogih industrija, dok će konsolidacijski pritisci biti pojačani u industrijama u kojima se granice šire. Nadalje, moguće je da se pojave nove organizacije u industriji zbog neopterećenosti naslijeđenom definicijom proizvoda i već naviknutim načinima konkuriranja na tržištu te bez povijesno stvorenog bazena profita kojeg moraju štititi (Porter, Heppelmann, 2014.). Osim promjena u industriji, nove tehnologije otvaraju spektar novih poslovnih modela za hvatanje vrijednosti, od verzije tradicionalnog modela vlasništva u kojem potrošač ostvaruje korist od novih poboljšanja usluge do modela proizvoda kao usluga u kojem proizvođač zadržava vlasništvo i preuzima potpunu odgovornost za troškove rada proizvoda i usluga u zamjenu za tekuću naknadu. Što omogućuje potrošačima da plaćaju kako koriste proizvod ili uslugu, a ne unaprijed. U takvom poslovnom modelu poboljšanja performansi proizvoda koja smanjuju operativne troškove ili povećavaju efikasnost usluge su u potpunosti zahvaćeni od strane proizvođača (Porter, Heppelmann, 2014.).

Kako bi promjene na razini industrija i poslovnih modela bile moguće, prethodno je potrebno na razini organizacija osigurati tehnološku infrastrukturu i poslovne prakse koje će inkorporirati nove tehnologije (Bresnahan, Greenstein, 1997.). Poslovne prakse u organizacijama zahtijevat će značajno drugačije promjene nego na što su zaposlenici navikli s obzirom da umjetna inteligencija sama može postići totalnu kontrolu kroz podatke za razliku od tradicionalnog menadžmenta, odnosno s dolaskom umjetne inteligencije, snaga se iz ruku hijerarhije menadžera pomiče prema većem kadru profesionalaca koji vladaju analitikom, programiranjem i poslovanjem. U tom pogledu, menadžment u organizacijama neće više biti ljudska (društvena) praksa, nego proces ugrađen u tehnologiju. Posljedično, organizacijsko učenje sve će više biti utjelovljeno u procese vođene tehnologijom (Schildt, 2017.).

Navedeno ukazuje da će potražnja za radnicima sa specifičnim vještinama ili visokim obrazovanjem samo rasti u budućnosti, što je u skladu sa zaključcima istraživanja Bresnahan, Brynjolfssona i Hitta iz 2002. Također u istom istraživanju znanstvenici zaključuju kako su računala učinila informacije značajno jeftinijima i sveprisutnima, što direktno povećava potražnju za ljudima koji mogu te informacije procesuirati na načine koje strojevi ne mogu, dalje vodeći do uskog grla radi preopterećenja informacijama u slučaju manjka istih, posebice na višim razinama hijerarhije. Kako organizacije ne bi patile radi preopterećenja informacijama, potrebna je efektivna upotreba računalnih sustava, odnosno pojedinci koji mogu smisliti načine kako iskoristiti prednost novih poslovnih procesa koji se pružaju upotrebom nove tehnologije. Detaljnije, organizacijama su potrebne nove kognitivne

vještine, duboko razumijevanje vlastite organizacije i potreba klijenata kod vlastitih zaposlenika. Organizacije će također morati razlikovati dvije vrste aktivnosti koje će opisani zaposlenici trebati odrađivati. Prva je sličnija znanstvenom istraživanju, koja kombinira kvantitativne informacije o potrošačima ili zaposlenicima s dubokim znanjem o poslovanju dok je druga vezana uz dizajniranje organizacija, proizvoda i usluga, kako bi se iskoristilo rezultate istraživanja prve vrste aktivnosti (Bresnahan, Brynjolfsson, Hitt, 2002.). Osim navedenih aktivnosti, u posljednjim godinama, s razvojem umjetne inteligencije koja počiva na velikim količinama podataka, došlo je do potrebe i za uslugama zaštite podataka, odnosno znanjima i sposobnostima koje će omogućiti organizacijama da zaštite privatne podatke svojih potrošača (Porter, Heppelmann, 2015.).

Porter i Heppelmann (2015.) predviđaju kako će napredak u tehnologiji i ekspanzija podataka koja se kreira njome, dovesti do novih industrija, novih usluga i novih uloga koje će zahtijevati više ljudi nego što je trenutno zaposleno, odnosno potražnja za radom će se prema njima samo povećavati dok će organizacije biti potrebne sve više se uključivati u obrazovanje i obrazovne procese kako bi osigurale dovoljnu količinu radnika s potrebnom količinom znanja. Izneseni zaključci su u skladu s ranijim istraživanjem Bresnahan, Brynjolfssona i Hitta (2002.), koje navodi da će organizacije koje implementiraju tehnologiju u svoje poslovanje zapošljavati više zaposlenika s vještinama i višom razinom obrazovanja te da će ulagati više u treninge postojećih zaposlenika te će tražiti nehijerarhijske oblike organiziranja kako bi zaobišle uska grla protoka informacija što će dodatno pozitivno utjecati na vrijednost zaposlenika koji posjeduju „timske“ sposobnosti i „autonomiju“ vještina. Detaljnije o utjecaju umjetne inteligencije i razvoja tehnologije bit će pokriveno u nastavku ovog rada.

Iz perspektive samih organizacija, osim promjena u potrebama za radom koje su već spomenute, Porter i Heppelmann (2015.) navode i sljedeće promjene koje će biti posljedica novih tehnologija. Logistika unutar poduzeća će se značajno unaprijediti, menadžment velikih flota vozila će se potpuno transformirati s mogućnošću daljinskog praćenja položaja i funkcija svakog vozila pojedinačno, istovremeno dajući optimiziranu dostavnu rutu vozačima s obzirom na uvjete u prometu ili vremensku prognozu. Mogućnost povezanosti s proizvodom i praćenja kako se koristi premješta fokus organizacija s prodaje (koja je često jednokratna transakcija) prema maksimiziranju potrošačeve vrijednosti od proizvoda kroz vrijeme. S upotrebom velikih podataka, organizacije mogu uspoređivati obrasce korištenja proizvoda i usluga i postići mnogo detaljniju segmentaciju korisnika – po industriji, geografiji, organizacijskoj jedinici i još detaljnijim atributima. Marketinški stručnjaci mogu primijeniti

duboko znanje kako bi prilagodili posebne ponude ili postprodajne pakete usluga, stvorili značajke za određene segmente i razvili sofisticirane strategije cijena koje više odgovaraju cijeni i usluzi na razini segmenta ili na pojedinačnog potrošača. Također, kako se fokus mijenja prema pružanju stalne vrijednosti potrošaču, proizvodi postaju sredstva isporuke te vrijednosti, a prestaju biti sami cilj. S obzirom da proizvođač postaje povezan s potrošačima preko proizvoda, ima novu bazu za direktni i trajni dijalog s njima. Organizacije uviđaju da proizvod, s razvojem tehnologije i prikupljanjem podataka o potrošačima, postaje prozor u potrebe i zadovoljstvo potrošača, umjesto da se potrošači oslanjaju na potrošače da nauče o potrebama i performansama proizvoda (Porter, Heppelmann, 2015.). Zaključno, znanje o tome kako potrošači zaista koriste proizvode povećava sposobnost tvrtke za segmentiranje kupaca, prilagođavanja proizvoda, postavljanje cijena radi boljeg prikupljanja vrijednosti i proširenja usluga s dodanom vrijednošću. Kako organizacije prikupljaju podatke o potrošačima, za potrošače se povećava trošak prelaska na proizvode konkurenta te češće ostaju lojalni jednom brandu, što također omogućava proizvođačima da smanje svoju ovisnost na pružatelje logističkih i distributerskih usluga, time značajno povećavajući svoj profit (Porter, Heppelmann, 2014.).

U središtu svega prethodno navedenog stoji upotreba velikih podataka i umjetne inteligencije koja će ih obraditi i pružiti detaljne uvide organizacijama. Podaci u sadašnjosti stoje paralelno s ljudima, tehnologijom i kapitalom kao osnovnom imovinom organizacija, a u mnogim organizacijama su možda postali i odlučujuća imovina. Iako su podaci o proizvodima i uslugama koji se direktno generiraju vrlo vrijedni za organizacije, njihova vrijednost raste eksponencijalno kada se integriraju s ostalim podacima kao što su povijest usluga, mjesta zaliha, cijene roba i obrasci prometa (Porter, Heppelmann, 2015.). Također, organizacije mogu iskoristiti podatke koje prikupe i za generiranje dodatnih prihoda, izvan uobičajenih, tako što će ih prodavati drugim organizacijama. Takva upotreba podataka kao imovine može dovesti do novih usluga i novih poslova (Porter, Heppelmann, 2014.). Sami podaci se, prema Porteru i Heppelmannu (2015.) u organizacije mogu prikupljati iz tri izvora: proizvoda i usluga koje organizacije prodaju, iz samog poduzeća te eksterno. Podaci prije analize se nalaze u „jezeru podataka“ (engl. *data lake*), odnosno na serverima u različitim formatima, tj. u sirovom obliku (engl. *raw data*). Analiza podataka u organizacijama dijeli se na četiri tipa: deskriptivna, dijagnostička, prediktivna i preskriptivna. Deskriptivna analiza podataka zahvaća stanje proizvoda, okruženja i operacija. Dijagnostička proučava uzroke umanjениh performansa ili kvarova proizvoda. Prediktivna detektira obrasce koji signaliziraju nadolazeće

dogadaje te preskriptivna identificira mjere poboljšanja ishoda ili ispravljanja problema. Upotrebom svih tipova analize podataka, dobivaju se dublje spoznaje o samoj organizaciji, potrošačima te partnerima koji se potom implementiraju u sadašnje i novije verzije proizvoda i usluga kako bi se postigla veća vrijednost za organizaciju i potrošače (Porter, Heppelmann, 2015.).

Svi navedeni benefiti i promjene koje dolaze kao posljedica ulaganja u tehnologiju, točnije umjetnu inteligenciju, imat će drastične posljedice na organizacije u budućnosti. To će zahtijevati organizacijske promjene koje ne smiju biti površne i parcijalne jer će dovesti do promašenih investicija i gubitka produktivnosti radi negativnih interakcija između postojećih organizacijskih praksa i procesa (Brynjolfsson, Renshaw, Van Alstyne, 1997.).

Također, organizacije će morati paziti i na negativnu stranu umjetne inteligencije, odnosno prikupljanja velike količine podataka. Organizacije će u prikupljanju vrijednosti od podataka, morati u obzir uzeti i potencijalne reakcije svojih potrošača jer će neki od njih biti bez brige za svoje podatke dok će drugi imati snažne osjećaje u vezi privatnosti svojih podataka i njihove ponovne upotrebe. Organizacije će morati identificirati mehanizme za pružanje vrijednih podataka trećim stranama bez povrede svojih potrošača (Porter, Heppelmann, 2014.). Osim povreda privatnosti potrošača, drugi problem koji se javlja prilikom implementacije umjetne inteligencije je mogući rast nejednakosti radi povećanja automatizacije i uvođenja novih zadataka (Acemoglu, Restrepo, 2018.).

3.3. Utjecaj umjetne inteligencije na promjene organizacijskih struktura

Neke od najzanimljivijih i najproduktivnijih razvoja bile su organizacijske inovacije. Telegraf je omogućio formiranje geografski raštrkanih organizacija; električni motor je industrijskim inženjerima pružio veću fleksibilnost u smještanju strojeva u tvornicama, drastično poboljšavajući proizvodnu produktivnost omogućujući redizajn tijeka rada. Parni stroj bio je u centru širokog skupa tehnoloških i organizacijskih promjena koje su pomogle pokrenuti prvu industrijsku revoluciju (Brynjolfsson, Hitt, 2000.). S razvojem velikih podataka i analitike i njihove šire primjene, omogućuju se nove forme organiziranja. Kako bi organizacije ostvarile

benefite umjetne inteligencije, moraju prisvojiti organizacijske strukture, procese i ciljeve koji će biti u skladu s primjenom nove tehnologije (Schildt, 2017.). Drugim riječima, tehnologija značajno mijenja barem jedan, ako ne i sve, faktore koji utječu na dizajniranje poslova te kao rezultat, uspješna primjena tehnologije podrazumijeva i razmišljanje o tome kako se posao organizira i tipove radnika koji su potrebni (Brynjolfsson, Hitt, 2002.).

Brynjolfsson i Hitt (2002.) u svojem istraživanju iznose kako je upotreba informacijskih tehnologija komplementarna novoj organizaciji radnih mjesta, koja uključuje veće odgovornosti za poslove linijskih radnika, veću decentraliziranost donošenja odluka i više samoupravljujućih timova. Osim toga, istraživanja su ukazala da je veća razina investicija u informacijsku tehnologiju povezana s manjim organizacijama i manje vertikalne integracije (Brynjolfsson, Hitt, 2000.). Nadalje, tehnologija povećava zahtjeve za vještinama i autonomiju među radnicima unutar organizacija. Gledano zajedno, rezultati istraživanja ističu ulogu organizacijskih promjena kao važnih komponenti tehnoloških promjena (Brynjolfsson, Hitt, 2002.).

Osim decentralizacije i autonomije, organizacijske strukture vjerojatno će postati manje krute jer će zaposlenici lakše uočiti mogućnosti suradnje, veća transparentnost rada na znanju povećat će raspon kontrole, dozvoljavajući jednom menadžeru da nadgleda i mentorira veći broj podređenih (Schildt, 2017.). Nadalje, na razini organizacija, volumen visoko kvalitetnih, digitalnih podataka u stvarnom vremenu je značajno povećan, što neizbježno vodi do bogatijih virtualnih prikaza organizacijskih aktivnosti i znanja. Budući da su informacije i znanje središnji izvori moći organizacija, podaci će se koristiti za optimizaciju i konfiguriranje onoga što organizacije rade i kako to rade. Drugim riječima, sljedeća desetljeća svjedočit će sve većoj „digitalizaciji menadžmenta“, odnosno napredni algoritmi i mogućnost obrade velikih količina podataka u stvarnom vremenu omogućit će organizacijama da izgrade „rutinsku pamet“ (engl. *routine smartness*) u svojim operacijama, na taj način mijenjajući postojeće elemente organizacijskog dizajna. Strukture i procesi unutar organizacija bit će nadograđeni optimizacijom i otvorenim informacijskim sustavima, što će dovesti do novih vrsta uloga i najvjerojatnije raširenih kulturnih promjena, odnosno pomaka u institucionaliziranim normama radnih mjesta (Schildt, 2017.).

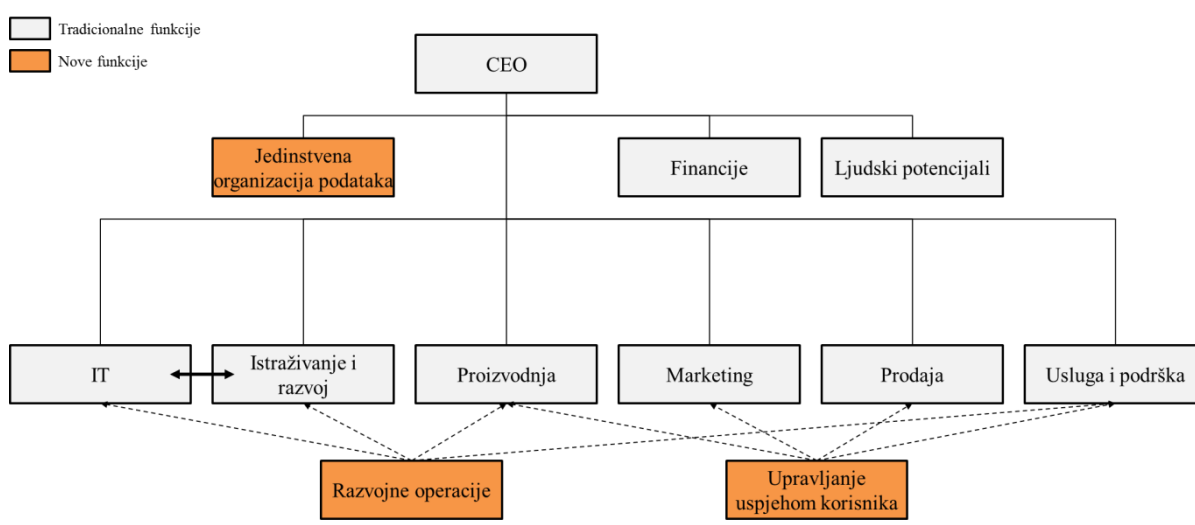
Detaljnije od razine samih organizacija, promjene uzrokovane implementacijom umjetne inteligencije, događat će se i na razini funkcija unutar organizacijskih struktura. Porter i Heppelmann (2015.) navode kako je u klasičnoj strukturi, poslovanje podijeljeno u funkcijske

jedinice, poput istraživanja i razvoja, proizvodnje, logistike, prodaje, marketinga, postprodajne usluge, financija i IT-a te da postoji i dodatno, u nekim slučajevima, i geografska dimenzija organizacijske strukture, koja dodaje sloj kompleksnosti. U takvim klasičnim strukturama, integracija kroz funkcijske jedinice odvija se dominantno kroz vodstvo organizacije i kroz dizajn formalnih procesa za razvoj proizvoda i usluga, menadžment nabavnog lanca, procesuiranje narudžbi i slične procese, u kojima nekoliko jedinica ima uloge. U novije vrijeme, navode Porter i Heppelmann (2015.), potreba za koordinacijom između dizajna proizvoda, rada u oblaku, poboljšanja usluga i angažmana kupaca je kontinuirana i nikada ne prestaje. Intenzivna, stalna koordinacija postaje potrebna kroz više funkcija, uključujući dizajn, operacije, prodaju, usluge i IT. Funkcijske uloge se preklapaju i zamagljuju. Nadalje, pojavljuju se potpuno nove funkcije od iznimne važnosti – na primjer, upravljanje svim novim podacima i novim otvorenim odnosima s potrošačima. Na najširem nivou, bogati podaci i povratne informacije koje se dobivaju, stavljaju pod upitnik tradicionalni centralizirani model upravljanja, u korist distribuiranih, ali visoko integriranih opcija uz neprestano unapređenje (Porter, Heppelmann, 2015.).

Detaljnije, Porter i Heppelmann (2015.), na razini pojedinačnih funkcija, ističu da će doći do veće i dublje suradnje između IT-a i istraživanja i razvoja. Kroz vrijeme, moguće je da će se te funkcije spojiti u jednu, dok je sigurno da će IT trebati preuzeti središnju ulogu u većini organizacija. Dodatno, organizacije će trebati formirati tri potpuno nove jedinice: jedinstvene organizacije podataka (engl. *unified data organizations*), grupe za razvojne operacije (engl. *dev-ops*) te jedinice za upravljanje uspjehom korisnika (engl. *customer success management units*). Kako bi organizacije najviše izvukle iz novih izvora podataka, odnosno resursa, mnoge organizacije će trebati stvoriti posebne jedinice specijalizirane za prikupljanje, objedinjavanje i analitiku te koje će biti odgovorne za stvaranje podataka i uvida dostupnima kroz sve funkcije i jedinice. Nove jedinice specijalizirane za podatke trebali bi biti vođene od strane visoko pozicioniranog menadžera, glavnog direktora za podatke (engl. *chief data officer*), koji direktno odgovara izvršnom direktoru ili ponekad glavnom direktoru za financije ili glavnom direktoru za informacijsku tehnologiju. Glavne zadaće te osobe trebale bi biti jedinstveno upravljanje podacima, educiranje ostalih u organizaciji kako primijeniti podatke kao resurse, nadzor prava i pristupa podacima i pokretanje primjene napredne analitike podataka kroz lanac vrijednosti. Grupa za razvojne operacije organizira i vodi timove koji skraćuju cikluse razvoja proizvoda i usluga, upravlja ažuriranjima proizvoda te isporučuje nove usluge i poboljšanja nakon prodaje. Također, nadgleda učestalo puštanje malih, pažljivo testiranih

serija promjena proizvoda u zajednički oblak, idealno bez ometanja postojećih proizvoda i korisnika na terenu. Jedinica za upravljanje uspjehom korisnika obavlja uloge za koje tradicionalne jedinice prodaje i usluga nisu opremljene i nemaju poticaja za usvajanje: praćenje korištenja proizvoda i podataka o izvedbi radi ocjenjivanja vrijednosti koju potrošači dobivaju i pronalaženje načina kako povećati tu vrijednost. Ova nova jedinica nije predviđena da radi samostalno, nego da kontinuirano surađuje s marketingom, prodajom i uslugama (Porter, Heppelmann, 2015.).

Slika 2: Nova organizacijska struktura



Izvor: Porter, Heppelmann, 2015., obrada autora

Porter i Heppelmann (2015.) zaključuju kako će organizacijska transformacija koju predviđaju biti evolucionarna, a ne revolucionarna te da će stare i nove strukture često trebati djelovati paralelno. S obzirom na opseg promjena i nedostatak vještina i iskustva, mnoge će organizacije početi s hibridnim ili tranzicijskim strukturama, što će omogućiti da se iskoristi oskudni talent, objedini iskustvo i izbjegne dupliciranje. Autori završavaju članak s tvrdnjom da tek započinjemo proces ponovnog pisanja organizacijske strukture koja je postojala već desetljećima.

Niža razina od funkcija su radna mjesta, odnosno poslovi koji će se mijenjati uslijed uvođenja i razvoja umjetne inteligencije. Balliester i Elsheikhi (2018.) navode da, usprkos intenzitetu postojećih debata na navedenu temu, trenutno nema zajedničke prihvaćene vizije budućnosti posla. Također iznose kako ne postoji niti suglasnost oko toga što su glavni pokretači koji će utjecati na buduće poslove i plaće. Autor (2015.) pak navodi kako novinari i stručni

komentatori često precjenjuju doseg zamjene ljudskih poslova strojevima pritom ignorirajući snažne komplementarnosti između automatizacije i ljudskog rada koje povećavaju produktivnost, povećavaju dohotke te povećavaju potražnju za radom. Jedino je sigurno kako tehnička izvedivost ne podrazumijeva uvijek ekonomsku izvedivost. Odnosno, da bi ljudski poslovi bili zamijenjeni strojevima, promjena u proizvodnom miksu mora biti razmjerno isplativija za organizacije od prethodnih radno intenzivnih proizvodnih procesa (Balliester, Elsheikhi, 2018.).

Znanstvena istraživanja, pogotovo u posljednjim godinama, sve se više bave ovom tematikom te pokušavaju otkriti koja zanimanja bi mogla nestati, a koja biti u većoj potražnji. Tako Autor (2015.) detaljno opisuje kako će strojevi zamijeniti radnike u obavljanju rutinskih zadataka koji se mogu kodirati, istodobno povećavajući komparativnu prednost radnika u pružanju vještina rješavanja problema, prilagodljivosti i kreativnosti. Ograničenje automatizacije je u tome što da bi stroj mogao izvršiti određeni zadatak, programer prvo mora u potpunosti razumjeti korake potrebne da se zadatak ispuni, a potom napisati program koji će omogućiti da stroj precizno ispuni te korake (iznimka je strojno učenje). Granica automatizacije, prema Autoru (2015.) brzo napreduje, a izazovi zamjene strojeva radnicima u poslovima koji zahtijevaju fleksibilnost, prosuđivanje i zdrav razum, ostaju veliki. Nadalje, navodi kako zadaci koji se ne mogu substituirati automatizacijom, često su nadopunjeni njome. Razlog zašto je još uvijek veliki problem automatizacije senzomotornih vještina, fizičke fleksibilnosti, zdravog razuma, intuicije, kreativnosti i govornog jezika je taj što su to sposobnosti koje je ljudska vrsta evoluirala, što znači da formaliziranje tih sposobnosti zahtijeva obrnuti inženjering skupa aktivnosti koje ljudi uobičajeno obavljaju koristeći samo prešutno razumijevanje (Autor, 2015.). Kao rezultat prethodno navedenog, isti autor navodi da organizacije u doba automatizacije imaju povećanu potražnju za dvije skupine radnika. Prva skupina su radnici s visokim razinama obrazovanja i znanja, koji imaju sposobnosti rješavanja problema, intuiciju, kreativnost i sposobnosti nagovaranja. Druga skupina su radnici koji imaju vještine prilagodljivosti situacijama, vizualnog i jezičnog prepoznavanja i interakcije, odnosno manualni radnici poput kuhara, čistača, majstora, medicinskih sestara i zaštitara. Te dvije kategorije radnika uglavnom se nalaze na suprotnim krajevima distribucije dohotka i razine obrazovanja, odnosno predviđa se da će automatizacijom doći do polarizacije poslova jer će rasti potražnja za navedene dvije kategorije, dok će poslovi s potrebnom srednjom razinom obrazovanja i vještina biti automatizirani (Autor, 2015.). Osim Autora, Luksha i suradnici (2015.) su analizirajući moguće efekte tehnologije na poslove u Rusiji do 2030.,

došli do zaključka kako će poslovi poput konduktera, poštara i pravnih savjetnika postati nepotrebni u budućnosti, ali da je na ukupnoj razini potencijal kreiranja novih poslova veći od automatizacije postojećih (Balliester, Elsheikhi, 2018.). Dok Acemoglu i Restrepo (2018.) zaključuju na tragu Autora, kako ljudi imaju komparativnu prednost u novim i složenijim zadacima te da ako je navedena komparativna prednost značajna, zaposlenost i udio rada mogu ostati stabilni u dugom roku, usprkos brznoj automatizaciji.

Brynjolfsson i Hitt (2002.) pak navode kako će automatizacija uključivati zamjenu ljudskog rada s niskim vještinama, ali i prenošenje na ljude raznih zadataka vezanih uz višu razinu usluge. Takve promjene, zaključuju autori, zahtijevat će vrlo različite promjene u sposobnostima radnika, počevši od onih kognitivnih do razumijevanja i interpretacije informacija koje će biti dostupne. Kao primjer koji ide u prilog prethodno iskazanom, Porter i Heppelmann (2015.) navode kako će nove tehnologije u organizacijama zahtijevati nove vještine kroz cijeli vrijednosni lanac, kao i nove stilove rada te kulturne norme.

Zbog navedenih promjena u potražnji za zanimanjima, javlja se problem nejednakosti. Acemoglu i Restrepo (2018.) tako navode kako automatizacija direktno uzima poslove od radnika bez vještina i time direktno povećava nejednakost, dok razvoj novih aktivnosti direktno pomaže radnicima s vještinama i na taj način isto povećava nejednakosti u kratkom roku dok standardizacija u dugom roku ograničava rast nejednakosti. Bresnahan, Brynjolfsson i Hitt (2002.) tvrde kako se potražnja za radnicima pomaknula prema onima s posebnim talentom, treningom, autonomijom ili menadžerskim sposobnostima dovodeći do povećanja u nejednakosti dohodaka. Također, Balliester i Elsheikhi (2018.) navode kako tehnološki napredak pomiče kompoziciju nacionalnog dohotka od rada prema kapitalu, time povećavajući povrate vlasnicima kapitala, dok je rast „superstar“ organizacija poput Googlea, Facebooka, Amazona i Applea doveo do još većih dohodovnih nejednakosti radi povećanog broja industrija u kojima pobjednik uzima sve.

Znanstvenici predviđaju kako će u rješavanju nejednakosti, ali i problema manjka radne snage, organizacije morati biti više uključene u obrazovanje i trening svojih sadašnjih i potencijalnih zaposlenika. Tako Acemoglu i Restrepo (2018.) tvrde da obrazovni sustav nije sposoban prilagoditi se potrebama novih zadataka u dinamičnom okruženju, što bi moglo dovesti do uskog grla na tržištu rada. Porter i Heppelmann (2015.) kao jedno od rješenja predlažu da organizacije trebaju implementirati nove modele regrutiranja, poput pripravnčkih programa s lokalnim sveučilištima i programa povezivanja s vodećim proizvođačima

tehnologije kako bi „posudili“ talent od istih. Također predlažu kako bi organizacije trebale nove pristupe u privlačenju i motiviranju talenata te navode kako su povlastice poput fleksibilnosti u poslu, usluga *conciiergea*, *sabbaticala*, i slobodnog vremena na poslu za rad na sporednim projektima od osobnog interesa već sada norma u visokotehnološkim organizacijama koje primarno zapošljavaju većinu talenata za kojima će u budućnosti biti najveća potražnja.

Završno, Autor (2015.) navodi kako u slučaju da ljudski rad uistinu postane nepotreban automatizacijom, tada naš glavni ekonomski problem neće biti nedostatak, nego distribucija jer je primarni sustav raspodjele dohodaka u tržišnim ekonomijama ukorijenjen u oskudici radne snage; građani posjeduju, ili stječu, skup dragocjenog ljudskog kapitala koji, zbog svoje oskudice, donosi protok prihoda tijekom karijernog puta. U slučaju da strojevi učine ljudski rad suvišnim, postojalo bi veliko ukupno bogatstvo, ali ozbiljan izazov u određivanju tko ga posjeduje i kako ga dijeliti (Autor, 2015.).

4. EMPIRIJSKO ISTRAŽIVANJE O ULOZI UMJETNE INTELIGENCIJE U ORGANIZACIJSKOJ STRUKTURI AMBIDEKSTERNE ORGANIZACIJE

4.1. Metodologija istraživanja

Kako bi se došlo do saznanja o ulozi umjetne inteligencije u organizacijskim strukturama ambideksternih organizacija provedeno je empirijsko istraživanje, kvalitativnog karaktera. Korištena metoda prikupljanja podataka bili su dubinski intervjui. Navedena metoda izabrana je radi mogućnosti dobivanja detaljnijeg uvida u tematiku s više aspekata, točnije njih tri: tehnološkog, organizacijskog te aspekta ljudskih potencijala. Intervjui sa sudionicima istraživanja bili su polustrukturirani, to jest, intervju je bio određen unaprijed pripremljenim pitanjima, ali se u toku intervjuja u određene teme ulazilo dublje nego što je to bilo određeno pripremljenim pitanjima. Pitanja su primarno bila podijeljena na dvije kategorije, prva koja je bila vezana uz umjetnu inteligenciju, a druga uz ambideksterne organizacije. Kroz obje kategorije pitanja pokušalo se pokriti tri razine, prva vezana uz strategije i vizije organizacija, odnosno promjene na najvišim razinama odlučivanja, zatim pitanja vezana uz strukture organizacija, odnosno promjene koje će se događati na samim organizacijskim strukturama te treća razina koja se vezala uz sposobnosti zaposlenika i menadžera koje su trenutno potrebne te koje će biti potrebne u budućnosti s promjenama tehnologije i organizacijskih postavki. Intervjui su provedeni u trajanju od minimalno sat vremena do maksimalnih dva sata. Intervjui su nakon pristanka sudionika snimani te kasnije transkribirani.

U sklopu istraživanja uzorak sudionika iznosio je 5. Navedeni sudionici odabrani su na temelju namjernog uzorkovanja. Do sudionika se primarno dolazilo kroz osobne kontakte istraživača te preko elektroničke pošte. Sudionici su birani radi svoje stručnosti u promatrana tri aspekta: tehnologije, organizacije i ljudskih potencijala. Minimalna razina obrazovanja sudionika je završeni 5-godišnji fakultet, dok su dvoje sudionika doktori znanosti. Dob sudionika u rasponu je od 32 do 70 godina. Godine iskustva sudionika u rasponu su od 9 do 50 godina radnog staža. Sve osobe trenutno su zaposlene u Gradu Zagrebu. Pozicije koje su

zauzimale su: redoviti profesor u trajnom zvanju, direktori odjela ljudskih potencijala te članovi uprava.

4.2. Rezultati istraživanja

Provedeni intervjui i stavovi sudionika ukazuju da će umjetna inteligencija u budućnosti imati sve veću ulogu u funkcioniranju organizacija te posljedično i u oblikovanju istih. Jedan od sudionika intervjua razlaže djelovanje umjetne inteligencije na dvije kategorije:

Umjetnu inteligenciju trebamo promatrati iz 2 aspekta. Jedan je robotika, odnosno automatizacija, koja se temelji na simuliranju ljudskog rada i njegovoj optimizaciji dok je drugi aspekt vezan uz strojno učenje i neuronske mreže. ...Drugi aspekt povlači sa sobom i socijalna pitanja s obzirom da može snažno utjecati na mišljenje pojedinaca jer povlači svoje zaključke iz gomile podataka te nameće automatski ljudima rješenja i razmišljanja....

S obzirom na specifičnosti ambideksterne organizacije, navedeno je vrlo lako povezati s postavkama ambideksternih organizacija te se može zaključiti kako će robotika i automatizacija imati značajan učinak na strani eksploatacije, odnosno optimizacije postojećih poslovnih procesa jer im je fokus na poboljšanju postojećih procesa koje ljudi obavljaju, poput zamjene ljudi strojevima u tvornicama automobila. Ipak, treba imati na umu kako neće sve aktivnosti u organizacijama biti moguće zamijeniti robotima jer kako ispitanik kaže:

Najveći potencijal robotike je u aktivnostima koje su repetitivne te imaju stabilne okoline, to jest, ponavlja se isti proces kroz veliki broj ponavljanja, dok sami proces ne smije imati previše specifičnosti kako bi ga lakše bilo kodirati. Aktivnosti poput mehaničara i vodoinstalatera nije moguće automatizirati zbog previše varijabli koje mogu biti različite.

Fokus automatizacije u sklopu eksploatacije će biti u zamjeni repetitivnih procesa s manje varijabli koje utječu na njih, dok će složenije aktivnosti ili jednostavne aktivnosti u složenom okruženju biti samo donekle automatizirane i time samo djelomično optimizirane. Svejedno bi utjecaj automatizacije trebao biti značajan i time otvoriti prostor eksploataciji trenutnog poslovanja i povećanju profitabilnosti primarno kroz smanjenje troškova zamjenom ljudi robotima.

Iz druge perspektive, strojno učenje i neuronske mreže, odnosno umjetna inteligencija koja se primarno temelji na softverima, imat će značajan utjecaj na strani eksploracije u ambideksternim organizacijama s obzirom da će moći generirati zaključke iz velikih količina podataka koje ljudi nisu u mogućnosti obraditi u ekonomski isplativom roku. Kako bi to bilo ostvarivo organizacije će trebati osigurati dovoljnu količinu informacija, odnosno kako ispitanik kaže:

Informacija je blago. Ako ja imam milijun korisnika, a netko sto milijuna, on je automatski bogatiji jer na sto puta većem setu podataka može raditi analize.

Navedeno ukazuje da će velike organizacije, pogotovo one s velikim bazama podataka, odnosno kojima potrošači ili one same interno generiraju svakodnevno velike količine podataka, imati veliku prednost te će moći ostvarivati veće prednosti u eksploraciji u slučaju da imaju dovoljno jake softvere za obradu tolikih količina podataka. U usporedbi s ljudima, navedeni softveri moći će donositi zaključke koji nisu logični ljudskom umu, ali koji bi mogli potpuno promijeniti trenutne poslovne modele i disruptirati postojeće industrije.

Osim pozitivnih implikacija koje će umjetna inteligencija imati na poslovanje poduzeća kroz eksploataciju i eksploraciju, promjene će se događati i unutar samih eksploatacijskih i eksploracijskih jedinica organizacije. Umjetna inteligencija će nužno eliminirati suvišne aktivnosti koje nisu ekonomski isplative, odnosno kako ispitanik sugerira:

...već sada postoji manjak poslova koji možete dati ljudima koji nisu spretni, intuitivni, to jest, nemaju inventivnost. Ako gledate Gaussovu krivulju, jednostavno uvijek će biti ljudi koji će biti manjih mentalnih mogućnosti, manjih fizičkih mogućnosti. Do sada smo uvijek imali te poslove, ali sad je sve manje tih poslova i pitanje je što će ti ljudi raditi. Ja bih rekao da kako sada stvari stoje i kamo idemo, da će pojedinci, odnosno menadžeri, imati još veću moć vrlo vjerojatno.

Drugim riječima, unutar struktura dogodit će se nestanak poslova koje je lako automatizirati te će poslove izgubiti ljudi s manjkom posebnih vještina, odnosno moguće je pojavljivanje nedostatka poslova u sredini hijerarhije s obzirom na vrlo nisku mogućnost supstitucije poslova na nižim razinama poput čistača, tehničke službe i slično, dok će poslovi menadžera na višim razinama postati još cjenjeniji nego što su trenutno. Time će zapravo doći do izravnivanja organizacijskih struktura i nestanka nekoliko razina u strukturi.

Jedan od sudionika povlači paralelu i s prethodnim tehnološkim naprecima te predviđa da će se u kratkom i srednjem roku napredak umjetne inteligencije manifestirati na vrlo sličan način

kao što je bio razvoj računalne ili internet tehnologije. Kao glavne funkcije unutar organizacije koje će biti zamijenjene navodi poslovnu administraciju, računovodstvo, financije i kontroling te prodaju i marketing dok druga sudionica navodi kako je zamjetan trend smanjenja potrebe za radom u *hard* industrijama (npr. industriji cementa, čelika, automobilske industriji) koje se fokusiraju na automatizaciju poslovnih procesa primarno u samoj proizvodnji te da će značajan broj aktivnosti u ljudskim potencijalima biti moguće automatizirati:

...tehnologija je snažno unaprijedila produktivnost na strani poslovne administracije i poslovnog menadžmenta, specifično u marketingu, računovodstvu, financijama, kontrolingu i svemu što je bitno za vođenje poslovanja... na taj način se omogućilo smanjenje troškova kroz smanjenje potrebe za radom kroz dizanje produktivnosti uslijed uvođenja novih tehnologija... a čini se kako i sad ovaj trenutni razvoj tehnologije, s naglaskom na umjetnu inteligenciju, djeluje u istom smjeru...

Sve češće čujem od organizacija iz tipične proizvodnje, poput cementara i metalske industrije, da je neka vrsta umjetne inteligencije opcija kao zamjena za radnike.

Postoji već sada jak pritisak da se selekcijska testiranja, radi manjka radnika u ljudskim potencijalima te velikog turnovera u organizacijama, provode online. Odnosno da se čovjek, zaposlenik u ljudskim potencijalima gotovo potpuno povuče iz selekcijskog procesa. Također, edukacijske aktivnosti koje provodi odjel ljudskih potencijala su već sada sve više prebačene u online svijet, posebice u audio i video materijale.

Za razliku od proizvodnih djelatnosti poput prethodno navedenih industrija, jedan od sudionika tvrdi kako će vrlo vjerojatno teško biti zamijeniti funkcije koje se temelje na pružanju direktne usluge potrošaču, odnosno koje se temelje na odnosu potrošač-pružatelj usluga, koje se u današnje vrijeme najčešće mogu pronaći u turističkoj industriji, odnosno industriji slobodnog vremena. Što je dodatno potvrđeno i razmišljanjem druge sudionice intervjua koja tvrdi kako iz psihološke perspektive ljudi imaju određena ograničenja prema tehnologiji, odnosno zamijeni određenih zanimanja robotima u uslužnim djelatnostima.

U wellness, health, convention, hrani i piću će uvijek biti taj odnos domaćina i klijenta koji će se temeljiti na pamperingu, odnosno udovoljavanju potrebama međuljudskih odnosa. Nisu jednostavno moguće zamjene u tim područjima i trebat će pričekati neko vrijeme kako će se ljudska vrsta prilagođavati nekim novim stvarima.

Homo sapiens drugačije reagira kada je nešto u androidnom obliku i ono što će biti jako zanimljivo je ulazak umjetne inteligencije u društvena zanimanja.

Dodatno, od tradicionalnih funkcija unutar organizacija, za funkcije istraživanja i razvoja te IT-a od strane više sudionika intervjua smatrano je kako će s većom implementacijom umjetne inteligencije značajno dobiti na važnosti i postati najbitnije funkcije unutar samih organizacija s obzirom da će postati centri za implementaciju novih tehnologija te analize podataka koje će iste tehnologije generirati.

...u današnje doba sve bržih promjena u poslovnom svijetu ti ćeš morati konstantno inovirati svoje proizvode ili usluge jer će uvijek netko u Kini ili Indiji moći za uz manje troškove u vrlo kratkom vremenu kopirati tvoj finalni proizvod ili uslugu.

IT odjel će trebati preuzeti veću odgovornost na sebe s dolaskom novih tehnologija jer bi kroz logiku stvari oni trebali imati i najviše znanja za uvođenje novih tehnologija i daljnje koordiniranje kroz organizaciju.

...podaci koji će se generirati unutar organizacija će biti glavno oružje odjela za inovacije koji će u budućnosti morati znati naučiti upravljati njima i uz pomoć tehnologije dolaziti do smislenih zaključaka za poslovanje firme.

Prilikom razvoja softvera, to jest primarno u tehnološkim organizacijama događa se da se većina posla odrađuje u timovima, odnosno projektno te se hijerarhijske razine drastično smanjuju ili potpuno brišu te su zaposlenici, primarno programeri, organizirani poput radnika u tvornicama prije tehnoloških napredaka, odnosno zaposlenici imaju svoj dio koda koji razvijaju te se u vremenskim intervalima izmjenjuju s drugim članovima tima na područjima kojima rade, ali nikada nemaju razumijevanje i uvid u puni opseg proizvoda ili usluge na kojima se radi. Pregled cijelog proizvoda ili usluge i delegiranje zadataka je u takvim timovima koncentrirano kod svega jedne ili nekoliko osoba koje imaju napredno poznavanje poslovanja, ali i tehnološkog aspekta proizvoda, odnosno mogućnosti i ograničenja proizvoda. Drugim riječima ispitanika:

...sve manji broj ljudi ima kompletnu sliku sustava na kojem radi. Jednostavno zbog toga što su se stvari toliko ubrzale da kod i naš alat koji ćemo koristiti mora biti gotov jučer. Ti si dobio svoju kućicu koju moraš napisati, to je nekoliko tisuća linija koda u toliko vremena. Postoji osoba koja to nadgleda i zna kako taj sustav funkcionira. To je trend i mislim da će taj trend biti drastičniji i drastičniji.

...u našem poduzeću radimo u modificiranim timovima prema proizvodima i klijentima. Za svaki tim imamo Team Leadera i Project Managera. Team Leaderi su zaduženi za administrativnu podršku timu dok Project Manager dodjeljuje zadatke na projektima.

S obzirom na prethodno navedeno, može se zaključiti kako će osobe koje će imati potrebna tehnološka znanja, ali i razumijevanje poslovnog aspekta proizvoda ili usluga organizacija, ostvarivati premiju u smislu nagrađivanja jer će biti sve potrebni organizacijama, a bit će ih sve teže pronalaziti s obzirom na manjak hijerarhijskih razina u organizacijama, odnosno težu izgradnju ljudskih potencijala unutar organizacija. U perspektivi ambideksternih organizacija, navedeno implicira da će vjerojatno najvažnija pozicija za ostvarivanje ambideksternosti organizacija u doba umjetne inteligencije biti ona izvršnog direktora za tehnologiju (engl. *chief technology officer* – *CTO*) koja će na strateškoj razini povezivati tehnološka znanja, odnosno mogućnosti i ograničenja implementirane umjetne inteligencije na strani eksploatacije i eksploracije te poslovno shvaćanje i razumijevanje strategije poduzeća.

Dodatno, u dugom roku otvara se mogućnost potpunog brisanja organizacijskih struktura i upitne održivosti organizacija kao takvih s obzirom na trendove sve manje povezanosti mlađih generacija s organizacijama i njihovim strategijama i vizijama, odnosno sve veće fluktuacije zaposlenika koja je skoro jedino motivirana materijalnim motivacijama, odnosno većim plaćama i drugim materijalnim beneficijama, a sve manje zastupljenom intrinzičnom motivacijom kod zaposlenika. U takvom obliku odnos radnika i organizacija svodi se na puko iznajmljivanje vremena i ekspertize od strane pojedinaca organizacijama koje u zamjenu za danu materijalnu nagradu dobivaju željeni rezultat procesa, a postupno i na kraju potpuno iščezavaju intrinzične motivacije zaposlenika s obzirom na potpuni gubitak hijerarhije i nemogućnost napretka u organizacijama te nemogućnosti povezivanja s vizijom i strategijom poduzeća. U tom pogledu, do mogućeg potpunog nestanka organizacija, ambideksterne organizacije mogle bi imati povećane probleme u formiranju strategija nagrađivanja i vezanja zaposlenika unutar organizacija, posebice unutar eksploracijskih jedinica koje rade na rizičnim, neizvjesnim projektima koji se mogu razvijati duži period bez vidljivih rezultata i povrata na investicije. U prilog iznesenim tezama o mogućem nestanku organizacija i problemima u zadržavanju zaposlenika u ambideksternim organizacijama idu i sljedeće izjave ispitanika:

...nakon tri mjeseca razmišljaju gdje će dalje otići. Osobnost čovjeka se totalno dislocirala od posla koji on radi... Teško se vidjeti u nekoj kompaniji (startupu) ako ne znaš hoće ona trajati sljedećih deset ili dvadeset godina ili može sutra umrijeti, onda na neki način je jako teško vezati se uz organizaciju.

Nama su najkritičniji zaposlenici koji su godinu dana zaposleni i to smo detektirali da je najkritičnije hoće li netko ostati u firmi ili otići.

Nama je dodatni izazov bio kad su počeli paušalni obrti. Neto isplata na račun je značajno veća u slučaju paušalnog obrta te smo radi toga imali velike probleme jer su zaposlenici htjeli biti zaposleni preko paušalnih obrta kako bi ostvarivali veće dohotke.

...zaposlenik je došao nakon završenog fakulteta u našu organizaciju raditi za početnu plaću od 8.000 kuna. On je nakon godinu dana tražio povišicu i mi smo mu je dali i on je za par mjeseci dao otkaz jer mu je netko drugi ponudio još više.

...na izlaznim intervjuima doživjela sam da mi zaposlenik kaže da je odnos poslodavca i njega uzajaman i da on prodaje sebe, a poslodavac njega plaća za to, ako će me netko platiti više, ja ću ići kod njega.

(iz perspektive poslodavca za kandidata na intervjuu) Ima neka znanja, idem ga upogoniti što prije i dok je tu da iskoristim to što on zna dok je tu. I mislim da stvarno trebamo i menadžerima mijenjati mindset da mi odgajamo ljude koji će biti dvadeset godina u firmi. To danas više ne postoji.

4.3. Ograničenja istraživanja

Primarno ograničenje ovog rada je veličina uzorka, odnosno niži broj ispitanih sudionika. U empirijskom istraživanju provedeno je pet intervjuja, odnosno niži broj koji ograničava generalizaciju dobivenih zaključaka istraživanja. Kako bi doneseni zaključci u ovom radu bili reprezentativniji, potrebno je provesti dodatna istraživanja i intervjuje vezane uz temu rada za dobivanje pouzdanijih rezultata. Također, uzorak je namjerni što je moglo dovesti do pristranosti prilikom selekcije sudionika, posebice s obzirom da je većina sudionika istraživanja kontaktirana putem osobnih kontakata.

Osim veličine uzorka, dodatno ograničenje jest i lokacija i iskustvo sudionika intervjuja. Naime, sve ispitane osobe trenutno rade te su većinu svog radnog iskustva odradili u organizacijama u Republici Hrvatskoj (ili u Socijalističkoj Federativnoj Republici Jugoslaviji). Navedeno ograničava spoznaje rada na jednu poslovnu kulturu i znanja na koja je veliki utjecaj imalo razdoblje tranzicije zbog kojeg određene najbolje poslovne prakse nisu potpuno implementirane u pojedinim industrijama u kojima su sudionici intervjuja zaposleni.

Također, sudionici intervjuja su zaposleni ili imaju iskustvo rada u organizacijama koje se smatraju velikim poduzećima u Republici Hrvatskoj, ali u globalnim terminima one su vrlo male, što ograničava generiranje informacija i baze podataka kojima su sudionici mogli raspolagati tijekom svojeg radnog staža, u usporedbi s velikim, globalnim sustavima koji djeluju na svim kontinentima.

Dodatno, iako su sudionici upoznati s terminom ambideksternih organizacija u teoriji, u praktičnoj primjeni sudionici nisu imali iskustva u kreiranju ili upravljanju ambideksternih organizacija te time nisu mogli dati dublje uvide u navedeno područje istraživanja.

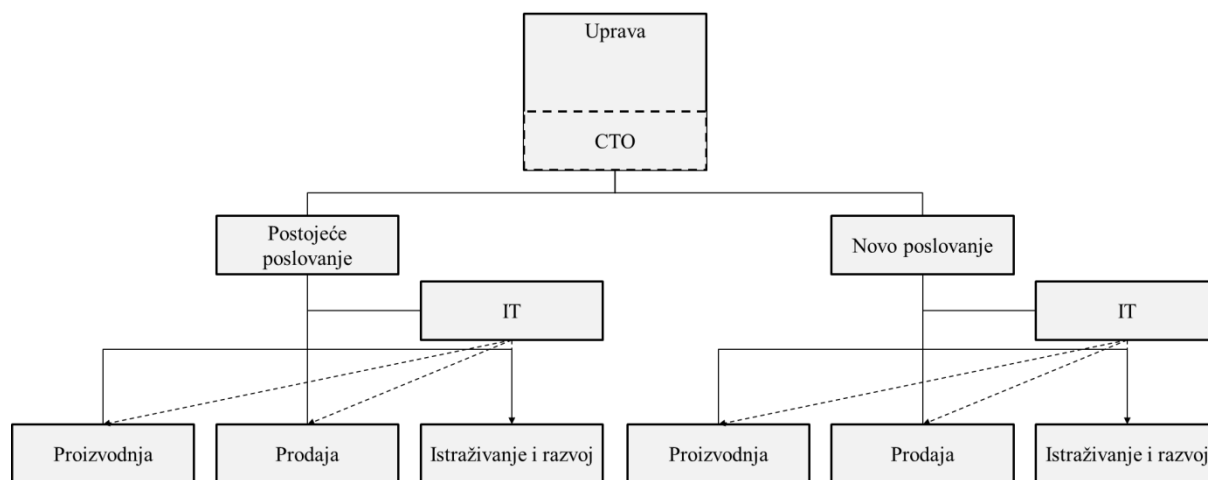
Nadalje, iskustvo sudionika s umjetnom inteligencijom je ograničeno na pojedina područja umjetne inteligencije poput robotike i strojnog učenja, dok područja poput neuronskih mreža i NLP platformi nisu područja interesa ispitanih sudionika što je moglo rezultirati pristranošću prema područjima umjetne inteligencije koja su područja ekspertize ispitanih sudionika.

5. ZAKLJUČAK

Zaključno, cilj ovog rada bio je utvrditi ulogu umjetne inteligencije u organizacijskim strukturama ambideksterne organizacije. Kroz rad je prikazan detaljni teorijski pregled recentnih istraživanja na temu umjetne inteligencije i organizacijskih struktura, s naglaskom na ambideksterne organizacije. Najveći utjecaj na ovaj rad iz teorijskog dijela imali su radovi Mintzberga (1980.), O'Reillya i Tushmana (2004.) te Portera i Heppelmanna (2015.) koji su prikazali organizacijske strukture te glavne sastavnice klasičnih organizacija, ambideksternih organizacija te organizacija pod utjecajem tehnologije. S druge strane, empirijsko istraživanje je pokazalo kako će umjetna inteligencija i njen razvoj u budućnosti imati značajnu ulogu u formiranju organizacija i njihovih struktura.

Kombinirajući saznanja iz teorijskog dijela rada te empirijskog istraživanja, predlaže se nova organizacijska struktura ambideksternih organizacija koja je prikazana na slici 3.

Slika 3: Prijedlog nove organizacijske strukture ambideksterne organizacije



U prijedlogu nove organizacijske strukture ambideksterne organizacije centralnu ulogu u eksploatacijskom i eksploracijskom poslovanju preuzima funkcija IT-a. Za razliku od današnje uloge IT-a u organizacijama, ovdje se predlaže da IT nije samo podrška postojećim funkcijama nego ključna funkcija koja u sebi objedinjuje aktivnosti prikupljanja i obrade velikih količina podataka te donošenja zaključaka koji se potom delegiraju na ostale poslovne funkcije, odnosno svojevrsna kombinacija aktivnosti koje bi odgovarale današnjim funkcijama IT-a te istraživanja i razvoja (inovacija).

IT bi ovim prijedlogom, u eksploatacijskom poslovanju trebao biti usmjeren na optimiziranje trenutnog poslovanja kroz automatizaciju, odnosno na smanjenje troškova i povećanje profita, kroz inkrementalne inovacije u dnevnim operacijama koje će donijeti efikasnost poslovanju te osigurati veću produktivnost rada dok bi IT u eksploracijskom poslovanju trebao biti usmjeren na korištenje podataka (iz eksploatacijskog poslovanja) i softvera koji će omogućiti njihovu naprednu obradu kako bi se došlo do spoznaja koje nije moguće otkriti ljudskim umom, to jest fokus takve IT funkcije trebao bi biti na kreiranju disruptivnih inovacija koje nisu moguće biti ostvarene kroz proces inoviranja poslovanja koji se temelji na ljudskim spoznajama i ljudskoj kreativnosti.

Kao centralna pozicija koja će objedinjavati oba poslovanja predlaže se izvršna osoba za tehnologiju (CTO – *chief technology officer*) koji bi trebao imati potrebna tehnološka znanja (automatizacije i softvera) te poznavanje poslovanja organizacije kako bi mogao kombinirati kontradiktornosti poslovanje te osigurati protok informacija između poslovanja.

U dugom roku, s mogućim postupnim nestajanjem organizacija, moguće je da će u prijelaznom periodu, IT funkcije ostati kao jedine u organizacijama s obzirom na njihovu moć koordiniranja i pozicije iznad ostalih poslovnih funkcija što im omogućuje direktno delegiranje i angažiranje vanjskih suradnika ovisno o potrebi.

Drugim riječima, znanje koje se trenutno nalazi u više poslovnih funkcija u organizacijama trebalo bi preći u centralnu funkciju – IT, koja će ovisno o eksploatacijskim ili eksploracijskim ciljevima poslovanja dalje koordinirati ostalim funkcijama, a biti pod direktnim nadzorom Uprava. Dok će u dugom roku postojati mogućnost da IT i Uprava ostanu jedine funkcije u formalnim organizacijama dok će se ostatak funkcija zamijeniti individualnim *outsourcingom* ili automatizacijom postojećih procesa.

1. Acemoglu, D., & Restrepo, P. (2018.), The race between man and machine: Implications of technology for growth, factor shares, and employment, *American Economic Review*, 108(6): 1488-1542.
2. Arrow, K. J. (1974.), *The limits of organization*, WW Norton & Company.
3. Autor, D., H. (2015.), Why Are There Still So Many Jobs? The History and Future of Workplace Automation, *Journal of Economic Perspectives*, 29(3): 3-30.
4. Balliester, T., & Elsheikhi, A. (2018.), *The future of work: A literature review* (No. 994987493402676). International Labour Organization.
5. Bresnahan, T. F., Brynjolfsson, E., & Hitt, L. M. (2002.), Information technology, workplace organization, and the demand for skilled labor: Firm-level evidence, *The Quarterly Journal of Economics*, 117(1): 339-376.
6. Bresnahan, T. F., & Greenstein, S. (1997.), Technical Progress and Co-Invention in Computing and in the Use of Computers, *Brookings Papers on Economic Activity: Microeconomics*, (January): 1-78.
7. Brynjolfsson, E., & Hitt, L. M. (2000.), Beyond computation: Information technology, organizational transformation and business performance, *Journal of Economic perspectives*, 14(4): 23-48.
8. Brynjolfsson, E., Renshaw, A. A., & Van Alstyne, M. (1997.), The matrix of change, *MIT Sloan Management Review*, 38(2): 37.
9. Coase, R. H. (1937.), The nature of the firm, *Economica*, 4(16): 386-405.
10. Cohen, L. E. (2013.), Assembling jobs: A model of how tasks are bundled into and across jobs, *Organization Science*, 24(2): 432-454.
11. Felin, T., Lakhani, K. R., & Tushman, M. L. (2017.), Firms, crowds, and innovation, *Strategic organization*, 15(2): 119-140.
12. Foss, N. J. (2003.), Selective intervention and internal hybrids: Interpreting and learning from the rise and decline of the Oticon spaghetti organization, *Organization Science*, 14(3): 331-349.
13. Kauppila, O. P. (2010.), Creating ambidexterity by integrating and balancing structurally separate interorganizational partnerships, *Strategic Organization*, 8(4): 283-312.

14. Lavie, D., Stettner, U., & Tushman, M. L. (2010.), Exploration and exploitation within and across organizations, *The Academy of Management Annals*, 4(1): 109-155.
15. Levinthal, D. A., & March, J. G. (1993.), The myopia of learning, *Strategic Management Journal*, 14(S2): 95-112.
16. Lubatkin, M. H., Simsek, Z., Ling, Y., & Veiga, J. F. (2006.), Ambidexterity and performance in small-to medium-sized firms: The pivotal role of top management team behavioral integration, *Journal of Management*, 32(5): 646-672.
17. March, J. G. (1962.), The business firm as a political coalition, *The Journal of Politics*, 24(4): 662-678.
18. March, J. G. (1991.), Exploration and exploitation in organizational learning, *Organization Science*, 2(1): 71-87.
19. Mintzberg, H. (1980.), Structure in 5's: A Synthesis of the Research on Organization Design, *Management Science*, 26(3): 322-341.
20. Nickerson, J. A., & Zenger, T. R. (2008.), Envy, comparison costs, and the economic theory of the firm, *Strategic Management Journal*, 29(13): 1429-1449.
21. O'Reilly III, C. A., Harreld, J. B., & Tushman, M. L. (2009.), Organizational ambidexterity: IBM and emerging business opportunities, *California Management Review*, 51(4): 75-99.
22. O'Reilly III, C. A., & Tushman, M. L. (2004.), The Ambidextrous Organization, *Harvard Business Review*, 82(4): 74-81.
23. O'Reilly III, C. A., & Tushman, M. L. (2013.), Organizational ambidexterity: Past, present, and future, *Academy of Management Perspectives*, 27(4): 324-338.
24. Pan, Y. (2016.), Heading toward artificial intelligence 2.0, *Engineering*, 2(4): 409-413.
25. Porter, M. E., & Heppelmann, J. E. (2014.), How smart, connected products are transforming competition, *Harvard Business Review*, 92(11): 64-88.
26. Porter, M. E., & Heppelmann, J. E. (2015.), How smart, connected products are transforming companies, *Harvard Business Review*, 93(10): 96-114.
27. Puranam, P., Alexy, O., & Reitzig, M. (2014.), What's "new" about new forms of organizing?, *Academy of Management Review*, 39(2): 162-180.
28. Rothaermel, F. T., & Alexandre, M. T. (2009.), Ambidexterity in technology sourcing: The moderating role of absorptive capacity, *Organization Science*, 20(4): 759-780.

29. Schildt, H. (2017.), Big data and organizational design—the brave new world of algorithmic management and computer augmented transparency, *Innovation*, 19(1): 23-30.
30. Smith, W. K., & Tushman, M. L. (2005.), Managing strategic contradictions: A top management model for managing innovation streams, *Organization Science*, 16(5): 522-536.
31. Van Looy, B., Martens, T., & Debackere, K. (2005.), Organizing for continuous innovation: On the sustainability of ambidextrous organizations, *Creativity and Innovation Management*, 14(3): 208-221.
32. Zenger, T. R., Felin, T., & Bigelow, L. (2011.), Theories of the firm—market boundary. *Academy of Management Annals*, 5(1): 89-133.
33. Zenger, T. R., & Hesterly, W. S. (1997.), The disaggregation of corporations: Selective intervention, high-powered incentives, and molecular units, *Organization Science*, 8(3): 209-222.

POPIS SLIKA

Slika 1: Ambideksterna organizacijska struktura	11
Slika 2: Nova organizacijska struktura.....	29
Slika 3: Prijedlog nove organizacijske strukture ambideksterne organizacije	41

POPIS TABLICA

Tabela 1: Determinante eksploatacije i eksploracije	9
---	---

PRILOZI

ŽIVOTOPIS KANDIDATA

OSOBNE INFORMACIJE **Nemčić Tin**

📍 Kustošijanska 213a, 10000 Zagreb (Hrvatska)

☎ (+385) 981347131

✉ tinnemcic@gmail.com

Datum rođenja 02/12/1995

RADNO ISKUSTVO

20/06/2017–danas **Junior Consultant**

Horwath HTL, Zagreb (Hrvatska)

- potpora u provedbi benchmark projekata
- izrada tržišnih analiza za sektor turizma
- procjena vrijednosti hotela
- dubinske provjere poslovanja
- izrada projektnih master planova

01/12/2015–01/10/2017 **Volonter**

eSTUDENT, Zagreb (Hrvatska)

- povezivanje poslodavaca sa studentima i traženje poslova studentima
- organizacija Starter konferencije, Starter mjeseca karijera, Career Speed Dating događaja u suradnji s Centrom karijera FER-a u kojem je sudjelovalo 30 poduzeća
- organizacija i provedba projekta Zlatni indeks 2015. i 2016. pod pokroviteljstvom Sveučilišta u Zagrebu

15/06/2016–09/09/2016 **Konobar**

Vail Resorts, Keystone (Sjedinjene Američke Države)

- zaposlen u sklopu programa Work & Travel
- rad u internacionalnom okruženju unutar hotelskog restorana

OBRAZOVANJE I OSPOBLJAVANJE

06/10/2014–06/2018

Ekonomski fakultet, Zagreb (Hrvatska)

Preddiplomski studij Poslovne ekonomije

OSOBNE VJEŠTINE

Materinski jezik **hrvatski**

Strani jezici

RAZUMJEVANJE		GOVOR		PISANJE
Slušanje	Čitanje	Govorna interakcija	Govorna produkcija	
engleski	C2	C2	C2	C1
njemački	B1	B1	A2	B1

Stupnjevi: A1 | A2: Početnik - B1 | B2: Samostalni korisnik - C1 | C2: Iskusni korisnik
Zajednički europski referentni okvir za jezike

Digitalne vještine

SAMOPROCJENA				
Obrada informacija	Komunikacija	Stvaranje sadržaja	Sigurnost	Rješavanje problema
Iskusni korisnik	Iskusni korisnik	Iskusni korisnik	Iskusni korisnik	Iskusni korisnik

Digitalne vještine - Tablica za samoprocjenu

- izvrsno znanje Microsoft Office programa
- poznavanje osnova programskog jezika Python
- poznavanje organizacijskog alata Trello
- poznavanje CRM sučelja HubSpot